

UNIVERSIDAD CARLOS III DE MADRID

ESCUELA POLITÉCNICA SUPERIOR

INGENIERÍA DE TELECOMUNICACIÓN



PROYECTO FIN DE CARRERA

**ESTRATEGIAS DE LOCALIZACIÓN Y SEGUIMIENTO
DISTRIBUIDOS EN REDES DE SENSORES**

AUTOR: Irene Castrejón Montero

TUTOR: Francisco Javier González Serrano

28 de Mayo de 2009

TÍTULO: *ESTRATEGIAS DE LOCALIZACIÓN Y SEGUIMIENTO
DISTRIBUIDOS EN REDES DE SENSORES.*

AUTOR: *Irene Castrejón Montero*

TUTOR: *Francisco Javier González Serrano*

La defensa del presente Proyecto Fin de Carrera se realizó el día 28 de Mayo de 2009; siendo calificada por el siguiente tribunal:

PRESIDENTE: *Jesús Cid Sueiro*

SECRETARIO *Matilde Pilar Sánchez Fernández*

VOCAL *Luis Santiago Garrido Bullón*

Habiendo obtenido la siguiente calificación:

CALIFICACIÓN:

Presidente

Secretario

Vocal

Agradecimientos

Llegado a este punto, tengo que mostrar mi mas sincero agradecimiento a mi Tutor, por su gran ayuda y apoyo, y porque ha entendido mis indisponibilidades de horario y en todo momento ha sabido ajustar sus tiempos a los míos. Muchas Gracias.

También tengo que agradecer a la Universidad las facilidades que me ha dado en todo momento para poder desarrollar mis estudios en las mejores condiciones.

Mi agradecimiento a los numerosos compañeros con los que he compartido ilusiones y trabajo en estos años de universidad, en especial a Inés, mi gran amiga, compañera y confidente. Por supuesto, no puedo dejar de acordarme de Manu, de Ramón, de César,..., y de tantos amigos que he hecho en esta etapa, y que espero mantener a lo largo del tiempo.

También quería dar las gracias a mis amigos del “cole”, por estar siempre ahí. En especial a Lauri, a Desi y a Elena, mis amigas del alma.

No quiero olvidarme de mis padres, que en todo momento han procurado las mejores condiciones para que yo pudiera dedicarme de lleno a lo que era mi objetivo principal: mis estudios. Y, fundamentalmente, gracias por quererme tanto. Tampoco quiero olvidarme de mis hermanos, Mariano y Pablo, que me han ayudado en los momentos de duda, a seguir adelante y luchar por mi objetivo.

Quiero tener, también, un recuerdo especial para mi abuela, María Jesús, que tanta compañía me ha hecho en esos “veranos largos” de estudios y para mis tíos y primos por estar siempre a mi lado.

Por último y no por ello menos importante, un recuerdo y agradecimiento muy especial a mi novio, Jorge, que con tanto cariño ha sabido “soportar” mis largas “ausencias” de la vida cotidiana y por su ayuda en los momentos que más la he necesitado.

GRACIAS A TODOS.

Piensa como piensan los sabios, mas habla como la gente sencilla

Aristóteles

Un minuto que pasa es irrecuperable. Conociendo esto, ¿cómo podemos malgastar tantas horas?

Mahatma Gandhi

Tengo un sueño, un solo sueño, seguir soñando.

Martin Luther King

Resumen

Las redes inalámbricas de sensores han sido consideradas como una de las tecnologías más importantes del siglo XXI. Están formadas por dispositivos pequeños y baratos, que llevan integrados distintos tipos de sensores, y que poseen capacidad de procesamiento y de intercomunicación mediante enlaces inalámbricos, lo cual permite la conexión de las redes de ordenadores y la comunicación con el mundo físico, abriendo, ante nosotros, un amplio abanico de aplicaciones en el campo de la seguridad, del control de procesos, etc. Una de las aplicaciones que más interés está suscitando en la sociedad, es la localización y seguimiento de objetos en movimiento. Este interés es debido a todos los posibles servicios derivados de dicha aplicación, que incluyen desde servicios críticos como la localización de accidentados en emergencias hasta otros más banales como la guía del usuario hasta el estanco más cercano.

A lo largo del trabajo, se exponen diferentes estrategias con el objetivo de resolver el problema de la estima de la trayectoria seguida por un blanco en movimiento, utilizando este tipo de redes. Dichas estrategias cubren desde la disposición en cuadrícula de una red formada por sensores acústicos, hasta el funcionamiento de la misma basada en líder. Además, propone la forma en qué combinar y adaptar diferentes algoritmos de localización y seguimiento ya existentes, teniendo en cuenta la diferencia entre ambos problemas. La solución propuesta se ha implementado con tres algoritmos de seguimiento diferentes: el Filtro de Partículas y ciertas variantes no lineales del Filtro de Kalman (*Extended Kalman Filter* y *Unscented Kalman Filter*), comprobando que en los tres casos se alcanza el objetivo. Debido al carácter secuencial de los algoritmos de seguimiento, éstos necesitan de un algoritmo de localización para comenzar a funcionar y para corregir posibles errores acumulados. Con tal fin se ha elegido un algoritmo de localización basado en la energía acústica. Finalmente, se exponen una serie de simulaciones para mostrar que con la solución propuesta logramos estimar de manera adecuada la trayectoria seguida.

Índice general

1. INTRODUCCIÓN	17
1.1. La localización y el seguimiento	18
1.2. Redes inalámbricas de sensores distribuidas	21
1.2.1. Ventajas e inconvenientes/restricciones	23
1.2.2. Localización y seguimiento en redes de sensores	24
1.3. Técnicas de estima de la posición mediante sensores	24
1.3.1. Triangulación	25
1.3.2. Análisis de la escena	27
1.3.3. Proximidad	28
1.4. Resumen	29
2. ALGORITMOS DE LOCALIZACIÓN Y SEGUIMIENTO	31
2.1. Algoritmos de localización	33
2.1.1. Algoritmos de localización que estiman $\hat{p}(\underline{x}_t \underline{z}_t)$ (<i>Tipo I</i>)	33
2.1.2. Algoritmos de localización que estiman \hat{x}_t (<i>Tipo II</i>)	35
2.2. Algoritmos de seguimiento	42
2.2.1. Algoritmos de seguimiento <i>Tipo I</i> : Estiman $\hat{p}(\underline{x}_t \underline{z}_t)$	44
2.2.2. Algoritmos de seguimiento <i>Tipo II</i> : Estiman \hat{x}_t	47
2.3. Resumen	52
3. SOLUCIÓN PROPIA PARA LA LOCALIZACIÓN Y EL SEGUIMIENTO	55
3.1. Descripción del blanco	56

3.2. Descripción de la red de sensores	57
3.2.1. Nodos acústicos	57
3.2.2. Despliegue en cuadrícula	59
3.2.3. Funcionamiento basado en líder	61
3.3. Descripción de la solución propia	64
3.3.1. Fase de inicialización	66
3.3.2. Fase de funcionamiento	67
3.4. Resumen	73
4. SIMULACIONES Y RESULTADOS	75
4.1. Trayectoria Vertical	76
4.2. Trayectoria Transversal	79
4.3. Trayectoria Aleatoria	81
4.4. Estudio del Ruido	83
4.5. Resumen	83
5. CONCLUSIONES	85
5.1. Futuras líneas de investigación	87
APÉNDICES	91
A. PRESUPUESTO DEL PROYECTO	91
A.1. Costes de material	91
A.2. Costes de Personal y Dirección	92
A.3. Presupuesto Total	93
B. ACRÓNIMOS	95
Bibliografía	97

Lista de Figuras

1.1. Dada la trayectoria unidimensional seguida por un blanco, la localización nos proporciona la posición ($x_{\text{localización}}$) conociendo únicamente la medida en dicho instante, mientras que el seguimiento nos proporciona la posición ($x_{\text{seguimiento}}$) sabiendo la estima en el instante anterior y la medida en el instante actual.	19
1.2. Localización y seguimiento de usuarios dentro de la vivienda	20
1.3. Experimento organizado por DARPA/IXOs SensIT (Sensor Information Technology) para la investigación de algoritmos de localización y clasificación de vehículos militares	20
1.4. Componentes de un nodo.	21
1.5. Nodo WINS NG 2.0.	22
1.6. Ejemplo de trayectoria seguida por un blanco en una región monitorizada por una red de sensores.	25
1.7. En 2D basta la medida de la distancia de 3 puntos no colineales al blanco	26
1.8. Triangulación por tiempo de vuelo en sistema GPS	27
1.9. Ejemplo de posicionamiento en 2D de un blanco con la técnica de angulation	27
1.10. La forma del horizonte extraída de una escena visual puede ser usada para localizar al observador o para calcular dinámicamente el movimiento de un vehículo que lleva una cámara montada.	28
1.11. Definidas las zonas de cobertura de tres puntos de acceso, la localización de un dispositivo con conectividad a los tres quedará restringida a la zona de intersección	29
2.1. Representación del funcionamiento del Filtro de Partículas	36

2.2. Situados dos sensores en $(-1,0)$ y $(1,0)$, se muestran los círculos de localización correspondientes a diferentes valores de κ (0.4, 0.6, 0.8)	39
2.3. Localización de un blanco usando cuatro sensores.	41
2.4. Ejemplo de $p(\underline{x}_t \underline{x}_{t-1})$ considerando la velocidad uniformemente distribuida entre $[0, v_{max}]$	43
2.5. Representación de la densidad de probabilidad $p(\underline{z}_t \underline{x}_t)$ para sensores de amplitud acústica.	44
3.1. Intervalos de muestreo y energía	59
3.2. El radio de cobertura acústica, R_{ca} , nos definirá la zona en la que un sensor es capaz de detectar la presencia de un blanco.	60
3.3. El radio de alcance RF , R_{rf} , nos definirá los nodos con los que se puede establecer comunicación.	60
3.4. Todo punto del terreno monitorizado estará cubierto por la cobertura de al menos 4 nodos.	61
3.5. El nodo líder será aquel más cercano al blanco.	62
3.6. Ejemplo de los diferentes estados por los que va pasando un nodo.	63
3.7. El líder va cambiando según la trayectoria seguida por el blanco.	64
3.8. Es importante distinguir entre los instantes de localización y los instantes de seguimiento.	66
4.1. Trayectoria vertical seguida por el blanco y estimada por los diferentes algoritmos. . . .	77
4.2. Error cometido por cada uno de los algoritmos para una trayectoria vertical.	77
4.3. Función de distribución y de densidad del error para una trayectoria vertical.	78
4.4. Trayectoria transversal seguida por el blanco y estimada por los diferentes algoritmos. .	79
4.5. Error cometido por cada uno de los algoritmos para una trayectoria transversal.	79
4.6. Función de distribución y de densidad del error para una trayectoria transversal. . . .	80
4.7. Trayectoria aleatoria seguida por el blanco y estimada por los diferentes algoritmos. . .	81
4.8. Error cometido por cada uno de los algoritmos para una trayectoria aleatoria.	81
4.9. Función de distribución y de densidad del error para una trayectoria aleatoria.	82
4.10. Error medio frente distintos valores de SNR mínima.	83

Lista de Tablas

4.1. Error medio para trayectoria vertical.	77
4.2. Error medio para trayectoria transversal.	79
4.3. Error medio para trayectoria aleatoria.	82
A.1. Costes de material	91
A.2. Fases del Proyecto	92
A.3. Costes de Personal y Dirección	92
A.4. Presupuesto Total	93

INTRODUCCIÓN

Las redes distribuidas de microsensors de bajo coste con capacidad de procesamiento de señal y de comunicación inalámbrica tienen multitud de aplicaciones entre las que se encuentra la localización y el seguimiento de blancos. Basándonos en dicha aplicación, hemos fijado como objetivo del proyecto proponer una serie de estrategias que permitan estimar de manera distribuida la trayectoria que va siguiendo un objeto en movimiento, a través de un terreno monitorizado por una red de sensores.

Tales estrategias consisten en combinar y adaptar ciertos algoritmos ya existentes. Antes de meternos a fondo con la solución propuesta, es fundamental conocer tanto la importancia de la localización y seguimiento en el mundo actual y las diferencias que existen entre ambos problemas, así como las características de las redes inalámbricas de sensores y el valor añadido que aportan.

A lo largo de este capítulo, se explicarán dichos conceptos y se expondrán las diferentes técnicas disponibles para la estima de la posición a partir de una magnitud física medida por varios sensores. El resto del trabajo está organizado de la siguiente manera: En el capítulo 2, se hará una descripción de algunos de los algoritmos de localización y seguimiento ya existentes, distinguiendo entre los que asumen el ajuste de los datos a un modelo estadístico y los que no lo asumen. Entre los algoritmos de localización descritos están el Filtro de Partículas y un algoritmo de localización basado en la energía acústica propuesto en [1]. Entre los de seguimiento están el Filtro de Partículas (**FP**) en su versión secuencial y el Filtro de Kalman con sus variantes no lineales (*Extended Kalman Filter*, **EKF**, y *Unscented Kalman Filter*, **UKF**). En el capítulo 3, se detallan una serie de estrategias para resolver el problema expuesto. Por una lado, se propone la distribución en cuadrícula de la red formada por sensores acústicos y su funcionamiento basado en líder. Por otro lado, se describe la forma en que se combina el algoritmo de localización basado en la energía acústica con algún algoritmo de seguimiento

(FP, EKF o UKF) para estimar la trayectoria seguida por el blanco. En el capítulo 4, se exponen una serie de simulaciones y resultados con el objetivo de mostrar el buen funcionamiento de la solución propuesta. Finalmente, se dan una serie de conclusiones y futuras líneas de investigación en el capítulo 5.

1.1. La localización y el seguimiento

En la actualidad existe un creciente interés en las tecnologías de localización y seguimiento de objetos en movimiento. Este interés proviene de todos los niveles de la sociedad, desde el gubernamental hasta el usuario final, que están demandando toda la clase de servicios basados en dicha tecnología. Éstos incluyen desde servicios críticos como la localización de accidentados en emergencias hasta otros más banales como la guía del usuario hasta el estanco más cercano a su posición [2].

Antes de dar una serie de ejemplos de aplicaciones de la localización y el seguimiento, conviene explicar la diferencia entre ambas tecnologías.

La localización consiste en determinar, en un determinado instante de tiempo, la posición de un objeto en movimiento. La determinación de dicha posición no depende de la posición del objeto en instantes anteriores sino de información instantánea obtenida de dicho objeto. En el seguimiento, el objetivo es el mismo, es decir, determinar la posición del objeto en un determinado instante. Sin embargo, para determinar dicha posición, el seguimiento necesita tanto la información obtenida del objeto, como el conocimiento de su posición en el instante anterior.

Es decir, la información con la que trabaja cada una de las tecnologías para alcanzar el objetivo es diferente. En la figura 1.1 podemos observar gráficamente dicha diferencia.

Normalmente, ambas tecnologías se aplican de manera conjunta para desarrollar un gran número de servicios basados en ellas. Las posibilidades de aplicación de la localización y el seguimiento son ilimitadas, es por ello que no paran de aparecer nuevos servicios ni de aumentar la demanda. Algunas aplicaciones típicas son las siguientes:

- **Seguimiento de equipo y personal en fábricas, residencias y hospitales.** En el caso de los hospitales y las residencias, el localizar rápidamente tanto el equipamiento como al personal permite responder de manera eficiente en situaciones que requieren una rápida actuación. Al mismo tiempo, es posible mantener un seguimiento exhaustivo de las actividades de los pacientes sin necesidad de limitar su privacidad ni de cargar excesivamente de trabajo al personal. En el caso




Figura 1.1: Dada la trayectoria unidimensional seguida por un blanco, la localización nos proporciona la posición ($x_{\text{localización}}$) conociendo únicamente la medida en dicho instante, mientras que el seguimiento nos proporciona la posición ($x_{\text{seguimiento}}$) sabiendo la estima en el instante anterior y la medida en el instante actual.

de las fábricas, la localización y seguimiento de mercancías y empleados mejora la productividad y el rendimiento.

- **Proporcionar información específica de localización en supermercados, museos o bibliotecas.** Esta aplicación permite hacer un estudio exhaustivo del comportamiento de los usuarios frente a determinados productos, obras o libros. A partir de dicho estudio sería posible realizar una colocación concreta de dichos productos, obras o libros para guiar a los usuarios a través de las diferentes estancias según distintas necesidades u objetivos.
- **Control de acceso a información y utilidades basada en la localización del usuario.** Esta aplicación está siendo ampliamente demandada dentro del mundo de la domótica [3]. Un sistema domótico para poder adaptarse a las preferencias de los usuarios debe ser capaz de determinar en cada momento en qué habitación se encuentran éstos dentro de la vivienda como muestra la figura 1.2. De esta forma, es posible permitir el acceso personalizado a determinada información y utilidades del hogar.
- **Seguimiento de tropas y vehículos militares.** Es en el campo de aplicación militar donde, históricamente, se ha llevado a cabo una intensa investigación en las tecnologías de localización y seguimiento. Esto es debido a que la detección de la trayectoria seguida por tropas y vehículos es clave en la estrategia militar. La figura 1.3 muestra un ejemplo de tal investigación.
- **Seguimiento de animales en libertad o semilibertad.** La localización y seguimiento de animales salvajes es fundamental para estudiar su comportamiento y está siendo ampliamente




Figura 1.2: Localización y seguimiento de usuarios dentro de la vivienda



Figura 1.3: Experimento organizado por DARPA/IXOs SensIT (Sensor Information Technology) para la investigación de algoritmos de localización y clasificación de vehículos militares

utilizado por investigadores. Sin embargo, también en el mundo de la ganadería esta tecnología resulta muy útil para el control y ubicación del rebaño, suponiendo un ahorro de recursos muy alto cuando el área de pastoreo es extensa.

- **Seguridad y detección de intrusos.** Por supuesto, en el campo de la seguridad, la detección y seguimiento de intrusos es fundamental. De ahí que sea una de las aplicaciones más demandadas.

Existen diferentes plataformas capaces de llevar a cabo la localización y el seguimiento. En nuestro caso, se han elegido las redes inalámbricas de sensores distribuidas para lograr dicho objetivo. De hecho, el proyecto lo que propone es un algoritmo de operación que permita a la red saber el camino seguido por un determinado blanco. A continuación, se detallan las principales características de este tipo de redes, lo que ayudará a entender, con posterioridad, ciertas decisiones tomadas en el diseño del algoritmo.

1.2. Redes inalámbricas de sensores distribuidas

En los años 90, las redes han revolucionado la forma en que las personas y las organizaciones intercambian información y coordinan sus actividades. Sin embargo, son las redes inalámbricas de sensores las que han sido consideradas como una de las tecnologías más importantes del siglo XXI [4].

La aparición de dispositivos pequeños y baratos, que llevan integrados distintos tipos de sensores, y que poseen capacidad de procesamiento y de intercomunicación mediante enlaces inalámbricos, ha permitido la conexión de las redes de ordenadores y comunicación con el mundo físico, abriendo, ante nosotros, un amplio abanico de aplicaciones en el campo de la seguridad, del control de procesos, de la exploración planetaria o de la diagnosis y monitorización médica [5].

Este tipo de redes denominadas redes inalámbricas de sensores están formadas por un conjunto de dispositivos autónomos, denominados nodos, que son distribuidos aleatoriamente en un determinado terreno. Cada nodo puede llevar integrado uno o más tipos de sensores que detectarán el fenómeno físico a estudiar (temperatura, sonido, vibración, presión, movimiento, etc.) y son capaces de establecer comunicaciones inalámbricas entre ellos. Además, cuentan con un microcontrolador, el cual es capaz de procesar los datos antes de transmitirlos y de manejar los protocolos de comunicación. A continuación se detallan cada una de las partes de las que consta uno de estos nodos (Figura 1.4) [6]:




Figura 1.4: Componentes de un de nodo.

- **Microcontrolador.** Se trata del cerebro del nodo. Se encarga tanto del procesamiento *on-board* de la información como del control del funcionamiento de los demás componentes del nodo.
- **Transmisor/Receptor RF.** Es el elemento que permite la comunicación entre los nodos, lográndose así el intercambio de información para el procesamiento distribuido de la señal.
- **Fuente de energía.** Las tareas tanto de sensado, como de procesamiento de la información y de comunicación implican un considerable gasto energético. Por ello es necesario dotar al sensor de

una fuente de energía. Como veremos más adelante, la energía constituye una de las principales limitaciones de estos dispositivos ya que, debido al tamaño de los nodos, no es posible la utilización de grandes fuentes.

- **Memoria externa.** Este componente permite el almacenamiento de parte de la información que ha sido procesada. Las memorias FLASH, son las más habituales en este tipo de redes ya que no consumen demasiada energía (recurso limitado).
- **Sensor.** Como vimos con anterioridad, un nodo puede llevar integrados uno o más sensores. Éstos proporcionan respuestas medibles a determinados fenómenos físicos, como son la temperatura, el sonido o la presión. Es decir, los sensores constituyen la interfaz con el mundo físico.
- **Convertor A/D.** Los sensores nos proporcionan señales analógicas que deben ser digitalizadas para poder ser procesadas. El convertor A/D se encarga de dicha digitalización.

La figura 1.5 muestra el nodo WINS NG 2.0 utilizado en el programa SensIT para poder construir y probar sus algoritmos distribuidos de sensores. Dicho nodo está equipado con tres tipos de sensores: acústico, sísmico y de infrarrojos [6].




Figura 1.5: *Nodo WINS NG 2.0.*

El diseño de una red inalámbrica de sensores es un trabajo laborioso ya que hay que conseguir aprovechar sus ventajas y superar los problemas técnicos que presenta. A continuación se exponen tanto las características que hacen de las redes inalámbricas de sensores una de las tecnologías más importantes, así como los inconvenientes a superar.

1.2.1. Ventajas e inconvenientes/restricciones

En las redes tradicionales de sensores están involucrados un número pequeño de sensores los cuales mandan la información sin tratar a una unidad central que se encarga del procesamiento. Por el contrario, las redes inalámbricas de sensores distribuidas, por definición, poseen una serie de características que las hacen ventajosas frente a dichas redes tradicionales [7].

- **Detección distribuida.** Cuando no se conoce la ubicación precisa de la señal de interés, el despliegue distribuido de los sensores en la región de monitoreo permite una mayor proximidad al fenómeno objeto de seguimiento. Esto permite aumentar la SNR y la probabilidad de visión directa. La SNR puede mejorar simplemente aumentando la sensibilidad del sensor, sin embargo, con el despliegue de un único sensor no encontramos ninguna solución para superar un obstáculo que nos obstruya la visión directa. Por tanto, la detección distribuida nos proporciona solidez frente a los obstáculos ambientales.
- **Comunicación inalámbrica.** Tanto el establecimiento de enlaces inalámbricos entre los sensores como el suministro de energía finita de forma local permiten el despliegue de este tipo de redes en zonas donde no hayan sido instaladas infraestructuras de comunicación y energía. Esta facilidad en el despliegue de la red hace más amplio el campo de aplicación de las redes de sensores.
- **Procesado distribuido.** Los nodos, al contar con un microcontrolador, tienen la capacidad de procesar la información. Dicha capacidad les permite tomar decisiones de forma local y reducir la cantidad de información a transmitir.

Sin embargo, las mismas características que, por un lado, dan valor a las redes inalámbricas de sensores, por el otro, les imponen una serie de restricciones con las que hay que contar a la hora de diseñar la red.

- **Energía finita.** Debido al despliegue distribuido de las redes en terrenos sin infraestructura energética y al reducido tamaño de los nodos, estos dispositivos deben operar utilizando pequeñas baterías locales. Lo cual implica que toda la operación de la red debe estar guiada por el ahorro energético. El mayor consumo se produce en las comunicaciones inalámbricas. Por ello es tan importante el procesamiento local de los datos con el objetivo de reducir al máximo el número de bits transmitidos. Otro límite que impone la escasez de energía a las comunicaciones es la distancia

máxima del radioenlace, lo que implica que un nodo sólo puede comunicarse con aquellos nodos situados dentro de su reducida zona de cobertura.

- ***Denso despliegue.*** Habitualmente este tipo de redes está formado por un gran número de nodos. Esta densidad en el despliegue de la red supone un reto en el diseño de los algoritmos colaborativos entre los nodos. Desde la temporización y el posicionamiento, hasta el procesado y la comunicación deben estar coordinados para conseguir una red eficiente en el uso de los recursos.
- ***Nodos desatendidos.*** La propia naturaleza de las redes inalámbricas de sensores distribuidas presupone el uso de nodos desatendidos que, al igual que cualquier dispositivo, son propensos a fallos y deben adaptarse dinámicamente a cambios en las condiciones ambientales. Esta operación desatendida implica que tanto la configuración, como la reconfiguración de la red debe ser automática. Por supuesto, esto no resulta una tarea fácil y debe ser tenido muy en cuenta.

1.2.2. Localización y seguimiento en redes de sensores

Las redes de sensores son ideales para la localización y seguimiento de objetivos. Éstas pueden cubrir extensas zonas y, gracias a su multiplicidad sensorial y modal, son capaces de detectar señales del objeto a seguir. Cada nodo adquiere información local. Dicha información es procesada y distribuida, de tal manera que con la combinación de la información de diversos nodos, la red es capaz de realizar una estima global de la posición.

La idea es que a lo largo de la trayectoria, en un instante determinado, son varios los sensores que, simultáneamente captan la señal emitida por el blanco como muestra la figura 1.6. El nivel de la magnitud captada será diferente en cada sensor. La combinación de dichas magnitudes nos permitirá determinar la posición del blanco.

Las diferentes formas en que se combinan la magnitud física medida por los sensores para la estima de la posición, da lugar a un conjunto de técnicas de estimación que se describen a continuación.

1.3. Técnicas de estima de la posición mediante sensores

Existen diferentes técnicas de estima de la posición mediante sensores. Podemos clasificar dichas técnicas en tres grandes grupos: estimación por triangulación, por análisis de la escena o por proximidad [8]. Por supuesto estas técnicas pueden aplicarse de manera aislada o conjuntamente para




Figura 1.6: Ejemplo de trayectoria seguida por un blanco en una región monitorizada por una red de sensores.

lograr el posicionamiento del blanco. A continuación se describen los conceptos básicos de cada uno de los grupos.

1.3.1. Triangulación

Las técnicas de posicionamiento basadas en triangulación usan las propiedades geométricas de los triángulos. Para la aplicación de dichas propiedades geométricas pueden utilizar, o bien la medida de la distancia (técnica denominada *lateration*), o bien la medida del ángulo/orientación (técnica denominada *angulation*).

Lateration

La técnica de *lateration* calcula la posición del objeto midiendo la distancia de dicho objeto a varios puntos de referencia. En el caso bidimensional basta con medir la distancia a tres puntos no colineales tal como muestra la figura 1.7. En el caso tridimensional serán necesaria la medida a 4 puntos no coplanares. Existen tres enfoques diferentes a la hora de medir la distancia:

- **Directa.** La medición directa de la distancia utiliza una acción física o un movimiento. Por ejemplo, un robot puede extender una sonda hasta que toque algo sólido o tomar las medidas con una cinta métrica. Las mediciones directas de la distancia son simples de entender pero difíciles de obtener automáticamente debido a la complejidad que supone la coordinación de movimientos físicos autónomos.
- **Tiempo de Vuelo.** Para el cálculo de la distancia de un objeto al punto de referencia P mediante




Figura 1.7: En 2D basta la medida de la distancia de 3 puntos no colineales al blanco

la técnica del tiempo de vuelo, se utiliza la medida del tiempo que tarda en llegar una señal emitida por el objeto hasta el punto P , siempre teniendo en cuenta que la velocidad de dicha señal es conocida.

$$\text{distancia} = \text{velocidad} \times \text{tiempo_vuelo}$$

Por ejemplo, sabiendo que la velocidad del sonido es aproximadamente 344 metros por segundo a una temperatura de 21°C, podremos deducir que un objeto está a 5 metros de distancia del punto P , si un pulso emitido por dicho objeto llega, al punto P , 14.5 milisegundos después. Por supuesto esta técnica puede utilizarse con señales de cualquier naturaleza: sonido, luz, radio. Dependiendo de dicha naturaleza, el sistema de medida precisará de relojes con menor o mayor resolución.

El GPS es uno de los sistemas que utiliza el tiempo de vuelo como técnica de medida de distancias. Los receptores GPS son capaces de calcular su posición tridimensional (latitud, longitud y elevación) usando 4 satélites. Los receptores no están sincronizados con los transmisores satélite, sin embargo, estos últimos sí están sincronizados entre sí. La hora local es transmitida en la señal, de tal manera que los receptores puedan calcular la diferencia entre el tiempo de vuelo de la señal emitida por cada satélite. La figura 1.8 muestra el funcionamiento de este sistema.

- **Atenuación.** La intensidad de una señal decrece a medida que la distancia al emisor aumenta. Se denomina atenuación a dicha disminución en relación con la intensidad original. Conocido tanto el modelo de atenuación de la señal con la distancia, así como la intensidad original de la emisión, es posible calcular la distancia entre el objeto emisor y un punto de referencia P , midiendo la intensidad con la que llega la señal a dicho punto. En esta técnica, para el correcto cálculo de la distancia, es fundamental que el modelo de atenuación de la señal con la distancia




Figura 1.8: *Triangulación por tiempo de vuelo en sistema GPS*

se ajuste lo más posible a la realidad.

Angulation

La técnica de *angulation* se basa en la medida de ángulos para determinar la posición del blanco. En general, en el caso bidimensional, basta con conocer el ángulo entre el objeto y dos puntos de referencia, y la distancia entre dichos puntos, tal y como muestra la figura 1.9. Una de las tecnologías




Figura 1.9: *Ejemplo de posicionamiento en 2D de un blanco con la técnica de angulation*

que utilizan esta técnica para localizar blancos son los arrays de antenas de fase. Múltiples antenas con separación conocida miden el tiempo de llegada de una señal. Conocida la diferencia entre dichos tiempos de llegada y la geometría del array, es posible calcular el ángulo desde donde fue emitida la señal. La *angulation* se podrá llevar a cabo si existen suficientes elementos en el array y la separación entre ellos es suficientemente grande.

1.3.2. Análisis de la escena

La técnica de localización basada en el análisis de la escena utiliza las características de una escena observada desde un punto de referencia para sacar conclusiones sobre la localización del observador

o de un objeto en dicha escena. Normalmente, las escenas observadas son simplificadas para obtener ciertas características que sean fáciles de representar y comparar (por ejemplo, la forma de siluetas en el horizonte, como muestra la figura 1.10).




Figura 1.10: *La forma del horizonte extraída de una escena visual puede ser usada para localizar al observador o para calcular dinámicamente el movimiento de un vehículo que lleva una cámara montada.*

En el análisis de escena estático, las características extraídas se comparan con un conjunto predefinido de datos para obtener la localización del objeto. Por el contrario, en el análisis dinámico, se sacan las diferencias entre escenas sucesivas para estimar la localización. Diferencias en escenas sucesivas corresponderá con movimientos del observador, y si se conoce la posición específica de alguna característica de la escena, el observador podrá calcular su propia posición relativa a dicha característica.

La escena, en sí misma, puede consistir en una imagen visual capturada por una cámara o en cualquier otro fenómeno físico apreciable, tal como las características electromagnéticas que aparecen cuando un objeto está en una posición y una orientación determinada. El sistema de localización RADAR constituye un ejemplo de esto último.

1.3.3. Proximidad

La técnica de estima de la posición basada en la proximidad determina cuando un objeto está “cerca” de un lugar conocido. Un fenómeno físico hace que se detecte la presencia del objeto. Existen tres enfoques generales para la detección de proximidad:

- ***Detectando el contacto físico.*** La detección de proximidad por contacto físico es el más básico de los enfoques. Dicho contacto puede ser detectado por sensores de presión, de contacto, etc.
- ***Monitorizando los puntos de acceso de una red inalámbrica.*** Monitorizando cuando un




Figura 1.11: Definidas las zonas de cobertura de tres puntos de acceso, la localización de un dispositivo con conectividad a los tres quedará restringida a la zona de intersección

dispositivo móvil están dentro de la zona de cobertura de uno o más puntos de acceso de una red inalámbrica es posible situar dicho dispositivo. La figura 1.11 muestra un ejemplo de aplicación de esta técnica.

- **Observando sistemas de identificación automáticos.** Esta última implementación de la técnica de localización por proximidad hace uso de los sistemas de identificación automáticos tales como cajeros, histórico de acceso a ordenadores, los registros de llamadas desde teléfonos fijos, etc.

1.4. Resumen

A lo largo del presente capítulo se ha descrito, de forma general, en que consiste el problema de la localización y el seguimiento. Se ha visto cómo dicho problema se reduce a la estima de la posición de un determinado objeto en movimiento, utilizándose para ello diferente información dependiendo de si se trata de localización o de seguimiento. Por supuesto, el conocimiento de la posición de un blanco tiene multitud de aplicaciones desde la localización de accidentados en emergencias, hasta el seguimiento de equipo y personal en fábricas y hospitales.

Posteriormente, se han analizado las redes inalámbricas de sensores distribuidas ya que es una de las plataformas capaces de resolver el problema de la localización y el seguimiento. Hemos visto como estas redes están formadas por dispositivos pequeños y baratos, que cuentan con sensores integrados

,y que poseen capacidad de procesamiento e intercomunicación. Las características de estos nodos hacen a este tipo de redes óptimas para la resolución del problema. Sin embargo, también cuentan con otra serie de características, entre las que se encuentra la escasa energía de la que disponen, que habrá que tener en cuenta a la hora de realizar el diseño de los diferentes algoritmos involucrados.

Finalmente se han descrito toda una serie de técnicas con las que a través de la medida realizada por los sensores, sobre el blanco, es posible descubrir su posición.

Dado que la localización y el seguimiento constituyen un campo ampliamente estudiado, existen multitud de algoritmos que los resuelven. A continuación, se explicarán detalladamente aquellos en los cuales está basada nuestra solución al problema.

ALGORITMOS DE LOCALIZACIÓN Y SEGUIMIENTO

La localización y el seguimiento mediante redes de sensores ha sido un campo ampliamente estudiado a lo largo de los años. Este estudio ha dado lugar a una serie de algoritmos con diferentes niveles de complejidad. Nuestro objetivo no consiste en crear un método novedoso sino, mediante una combinación de algunos ya existentes, conseguir realizar esta tarea de la manera más sencilla y con el menor gasto de recursos posible. En el problema de la localización y el seguimiento se pretende estimar el estado/posición del blanco/sistema que evoluciona con el tiempo, utilizando para ello una secuencia de medidas (ruidosas) que se realizan sobre el sistema en instantes discretos. Por tanto, el problema puede ser abordado mediante el modelo de espacio de estados y la formulación discreta en el tiempo [9].

El vector de estado, (2.1), contiene toda la información necesaria para describir el estado del sistema. En nuestro caso, dicho vector contendrá una o varias características cinemáticas del blanco según el problema que estemos tratando. Por ejemplo, si el blanco tiene un movimiento con aceleración, el vector de estado tendrá la siguiente forma.

$$\underline{x}_t = \begin{bmatrix} \underline{r}_t \\ \underline{\dot{r}}_t \\ \underline{\ddot{r}}_t \end{bmatrix} \quad (2.1)$$

donde \underline{r}_t , $\underline{\dot{r}}_t$ y $\underline{\ddot{r}}_t$ representan la posición, la velocidad y la aceleración del blanco, respectivamente.

Para analizar y hacer inferencia acerca del estado de un sistema, se necesitan, al menos, dos modelos:

- **El modelo del sistema.** Describe la evolución temporal del estado del sistema. Está relacionado

con las características cinemáticas del blanco.

$$\underline{x}_t = f(\underline{x}_{t-1}, \underline{v}_{t-1}) \quad (2.2)$$

donde la función f relaciona el estado, en el instante actual t , con el estado en instante pasado $t - 1$, y \underline{v} representa el ruido en el proceso.

- **El modelo de medida.** Cuantifica la relación entre el estado del sistema y las medidas realizadas sobre él. Está íntimamente relacionado con la naturaleza del sensor.

$$\underline{z}_t = h(\underline{x}_t, \underline{n}_t) \quad (2.3)$$

donde la función h relaciona el estado con la medida, ambos en el instante actual, y \underline{n} representa el ruido en la medida.

Tanto en la localización como en el seguimiento, el objetivo es estimar el estado del blanco, sin embargo, la información que se dispone para dicho fin es diferente en cada problema. En el caso de la localización, únicamente se dispone de la medida actual realizada sobre el sistema, por tanto, sólo el modelo de medida, (2.3), será útil para alcanzar el objetivo. Por el contrario, en el caso del seguimiento, se dispone también de la posición del blanco en el instante anterior, así que el problema es resuelto utilizando tanto el modelo del sistema, (2.2), como el de medida, (2.3).

Por otra parte, tanto en el problema de localización como en el de seguimiento, se asume que tales modelos están descritos de un modo probabilístico. Por tanto, en ambos, casos el objetivo será construir la función de densidad de probabilidad (*Probability Density Function*, PDF) a posteriori del estado, $p(\underline{x}_t | \underline{z}_t)$, basándose en la información disponible en cada caso. Sin embargo, no todos los algoritmos que resuelven ambos problemas estiman de manera completa dicha PDF, pudiendo hacer una pequeña clasificación de los mismos.

Por un lado, distinguiremos los algoritmos que no asumen ninguna distribución estadística de los datos y, por tanto, buscan una representación no paramétrica de la PDF a posteriori, es decir, estiman $\hat{p}(\underline{x}_t | \underline{z}_t)$. Tales algoritmos serán denominados “Algoritmos Tipo I”. El estado del blanco vendrá definido como la media de la distribución, por tanto, podrá ser estimado, a partir de la PDF a posteriori, según la siguiente ecuación:

$$\hat{\underline{x}}_t = E[\underline{x}_t | \underline{z}_t] = \int \underline{x}_t \hat{p}(\underline{x}_t | \underline{z}_t) d\underline{x}_t \quad (2.4)$$

Por el contrario, los algoritmos denominados “Algoritmos Tipo II”, asumirán que los datos se ajustan a una distribución conocida y, por tanto, les bastará con estimar los parámetros que representan dicha

distribución para resolver el problema. Posteriormente veremos que, habitualmente, es la distribución gaussiana la que más se ajusta a los datos, por tanto, dado que el parámetro que se calculará será su media, se puede decir, que estos algoritmos estiman directamente $\hat{\underline{x}}_t$.

A lo largo del presente capítulo se explicará de manera detallada tanto los algoritmos utilizados para localización, como los utilizados para seguimiento, diferenciando entre los que estiman directamente el estado, $\hat{\underline{x}}_t$, y los que estiman la densidad de probabilidad a posteriori del estado, $\hat{p}(\underline{x}_t|\underline{z}_t)$.

2.1. Algoritmos de localización

Podemos definir la localización como la estimación del vector de estado \underline{x}_t , en el instante actual, asumiendo, únicamente, el conocimiento de la medida realizada sobre el sistema, en el momento actual \underline{z}_t .

Dado que sólo se conoce tal medida, el único modelo que nos es útil para el problema de la localización es el modelo de medida, (2.3).

Cuando no se asume ninguna distribución estadística de los datos, el objetivo de la localización es la estimación no paramétrica de $p(\underline{x}_t|\underline{z}_t)$. Los algoritmos que obtienen dicha estimación son los denominados “Algoritmos de localización *Tipo I*”.

En nuestra particular clasificación, existen otra clase de algoritmos de localización que denominaremos *Tipo II* cuyo finalidad es estimar directamente \underline{x}_t . La estimación directa es posible ya que se asume que los datos se ajustan a una distribución normal, y, por tanto, basta estimar la media de dicha distribución para resolver el problema. Estos algoritmos, para conseguir su objetivo, adicionalmente hacen uso de alguna de las técnicas de estima de la posición mediante sensores que vimos en el capítulo anterior.

2.1.1. Algoritmos de localización que estiman $\hat{p}(\underline{x}_t|\underline{z}_t)$ (*Tipo I*)

El resultado de los algoritmos de localización *Tipo I* será la distribución de probabilidad a posteriori del estado del blanco $p(\underline{x}_t|\underline{z}_t)$, a partir de la cual se calculará la estimación del estado $\hat{\underline{x}}_t$, según la ecuación (2.4).

Los citados algoritmos basan el cálculo de $p(\underline{x}_t|\underline{z}_t)$ en el Teorema de Bayes:

$$p(\underline{x}_t|\underline{z}_t) = \frac{p(\underline{z}_t|\underline{x}_t) p(\underline{x}_t)}{p(\underline{z}_t)} \quad (2.5)$$

donde $p(\underline{z}_t)$ es una distribución marginal, también conocida como constante normalizadora. Por tanto, la ecuación (2.5) puede reescribirse como:

$$\begin{aligned} p(\underline{x}_t|\underline{z}_t) &= k p(\underline{z}_t|\underline{x}_t) p(\underline{x}_t) \\ p(\underline{x}_t|\underline{z}_t) &\propto p(\underline{z}_t|\underline{x}_t) p(\underline{x}_t) \end{aligned} \quad (2.6)$$

donde $p(\underline{z}_t|\underline{x}_t)$ es el modelo de medida y \propto significa proporcional.

Por norma general, es imposible evaluar analíticamente estas funciones de distribución ya que los algoritmos *Tipo I* buscan una representación no paramétrica de las mismas, evitando cualquier tipo de suposición adicional. Este hecho supone un aumento muy elevado del coste computacional y de recursos, por ello es necesario la obtención de modelos aproximados de dichas funciones de distribución.

Uno de los algoritmos más populares que realiza dicha aproximación basándose en métodos de integración numérica es el Filtro de Partículas (FP). Este ha sido el algoritmo elegido como ejemplo de los algoritmos de localización *Tipo I*. A continuación, se explica con más detalle su funcionamiento.

Filtro de partículas

La idea clave del Filtro de Partículas es la representación de la distribución de probabilidad a posteriori $p(\underline{x}_t|\underline{z}_t)$ mediante un conjunto de muestras discretas con pesos asociados:

$$\begin{aligned} \left\{ \underline{x}_t^{(i)}, w_t^{(i)} \right\}_{i=1}^N \\ w_t^{(i)} \propto p(\underline{x}_t^{(i)}|\underline{z}_t) \end{aligned} \quad (2.7)$$

donde $\underline{x}_t^{(i)}$ representa la muestra i de la densidad de probabilidad a posteriori $p(\underline{x}_t|\underline{z}_t)$, $w_t^{(i)}$ es el peso asociado a la muestra $\underline{x}_t^{(i)}$, y N es el número de muestras. Las muestras son denominadas partículas y su peso está relacionado con el modelo de medida por la ecuación (2.6). El valor de dicho peso, $w_t^{(i)}$, es proporcional a la probabilidad de que, en el instante t , el estado del blanco fuera igual a la partícula i ($\underline{x}_t = \underline{x}_t^{(i)}$) dada la medida, \underline{z}_t .

Esta técnica de simulación de muestras, a partir de una distribución conocida para aproximar la función de distribución objetivo por medio de la ponderación de esas muestras utilizando pesos, se denomina **Muestreo Enfatizado** (*Importance Sampling*). Sabiendo que los pesos se normalizan ($\sum_i^N w_t^{(i)} = 1$), la distribución de probabilidad a posteriori se puede aproximar mediante la expresión:

$$\hat{p}(\underline{x}_t|\underline{z}_t) \approx \sum_{i=1}^N w_t^{(i)} \delta(\underline{x}_t - \underline{x}_t^{(i)}) \quad (2.8)$$

La técnica de muestreo enfatizado sufre un serio inconveniente conocido como “degeneración de los pesos” (*weight degeneracy*) o “empobrecimiento de la muestra” (*sample impoverishment*). Este fenómeno consiste en que, con el paso del tiempo, la importancia de los pesos tiende a degenerar. Es decir, con el tiempo, la mayoría de las muestras no contribuyen a la aproximación de la distribución y, por tanto, se emplea mucho esfuerzo computacional en calcular pesos de muestras cuya contribución a la estimación es muy poco apreciable. Una medida apropiada de la degeneración de los pesos es el “tamaño efectivo de la muestra” (*effective sample size*), que se define del siguiente modo:

$$N_{ef} = \frac{1}{\sum_{i=1}^N \left(w_t^{(i)}\right)^2} \quad (2.9)$$

donde $w_t^{(i)}$ son los pesos normalizados. Como idea intuitiva, N_{ef} estima el número de partículas “útiles” en el conjunto de muestras, entendiendo como útil, aquélla que contribuye significativamente a la aproximación de la distribución. Como necesariamente se debe cumplir que $1 \leq N_{ef} \leq N$, pueden alcanzarse los siguientes casos extremos:

- Si los pesos son uniformes, es decir, $w_t^{(i)} = \frac{1}{N} \forall i = \{1, \dots, N\}$, entonces $N_{ef} = N$.
- Si $\exists j \in \{1, \dots, N\} \mid w_t^{(j)} = 1$ y $w_t^{(i)} = 0 \forall i \neq j$, entonces $N_{ef} = 1$.

Por lo tanto, un valor reducido de N_{ef} indica una degeneración severa. Si $N_{ef} \leq N_{umbral}^1$, se lleva a cabo la técnica de **Remuestreo**.

Dicha técnica da como resultado, a partir de la población $\{\underline{x}_t^{(i)}, w_t^{(i)}\}_{i=1}^N$, un nuevo conjunto de partículas $\{\underline{x}_t^{(i)*}, 1/N\}_{i=1}^N$ con pesos uniformes. El nuevo conjunto de muestras aleatorias $\{\underline{x}_t^{(i)*}\}_{i=1}^N$ se genera remuestreando y reemplazando el conjunto de muestras $\{\underline{x}_t^{(i)}\}_{i=1}^N$, de tal forma que la probabilidad de elegir a una partícula está directamente relacionada con el valor de su peso, es decir, $p(\underline{x}_t^{(i)*} | \underline{x}_t^{(j)}) \propto w_t^{(j)}$. La figura 2.1 muestra el funcionamiento del algoritmo completo.

2.1.2. Algoritmos de localización que estiman $\hat{\underline{x}}_t$ (*Tipo II*)

El resultado de los algoritmos de localización *Tipo II* es directamente la estimación del vector de estado $\hat{\underline{x}}_t$. La estimación directa es posible ya que se asume que los datos se ajustan a una distribución normal, y, por tanto, basta estimar la media de dicha distribución para resolver el problema. Estos

¹Donde N_{umbral} es un parámetro experimental a partir del cual se considera que la degeneración de la población de partículas requiere la participación de una etapa de remuestreo.

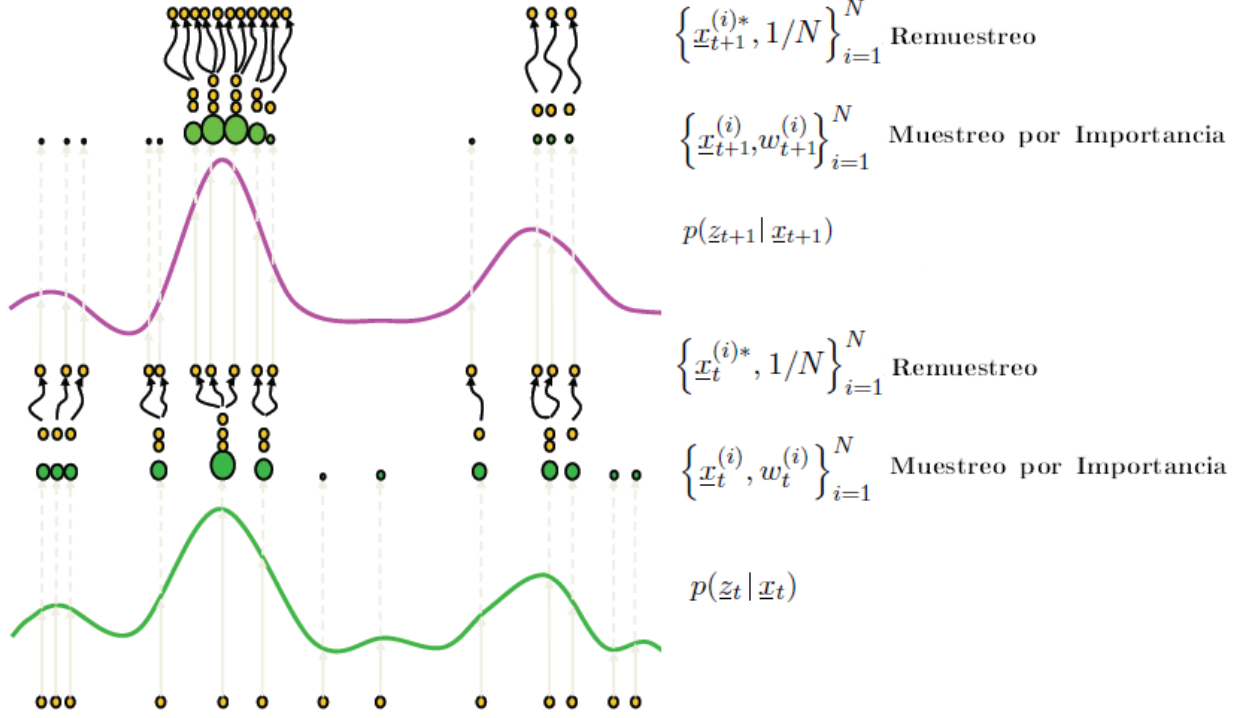


Figura 2.1: Representación del funcionamiento del Filtro de Partículas

algoritmos, para conseguir su objetivo, adicionalmente hacen uso de alguna de las técnicas de estima de la posición mediante sensores que vimos en el capítulo anterior.

Como vimos con anterioridad, este tipo de algoritmos requieren el conocimiento del modelo de medida (ecuación (2.3)) que dependerá del tipo de sensor utilizado. Como algoritmo de localización ejemplo de los de *Tipo II*, hemos elegido el algoritmo basado en la energía acústica desarrollado en [1]. Este algoritmo asume la utilización de sensores acústicos y las siguientes premisas [10]:

- El sonido se propaga en espacio libre y el medio de propagación es aproximadamente homogéneo. Por tanto, no aparece el fenómeno de la reverberación.
- La fuente se modela como un emisor puntual y omnidireccional. Para ello se asume que el objeto es relativamente pequeño comparado con la distancia al sensor.
- El retardo de la señal debido a la distancia del sensor al objeto es despreciable.

Por tanto, el modelo de medida puede ser definido mediante la siguiente expresión:

$$z_t^{(i)} = g^{(i)} \cdot \frac{s_t}{|\underline{r}_t - \underline{r}^{(i)}|^2} + n_t \quad (2.10)$$

donde $z_t^{(i)}$ es la energía acústica medida por el sensor i , s_t la señal emitida por el objeto, \underline{r}_t la posición del objeto y n_t el ruido en la medida, todos medidos en el instante t . $\underline{r}^{(i)}$ es la posición del sensor i que mide la energía.

En este caso, la medida únicamente depende de la posición del blanco, \underline{r}_t , por tanto, ésta será la única propiedad cinemática del vector de estado \underline{x}_t que podrá ser estimada mediante el algoritmo basado en la energía acústica.

Como vimos, este tipo de algoritmos también requieren la asunción de ciertos estadísticos. En este caso, dado que para el cálculo de un valor de energía se utilizan multitud de muestras de la señal acústica medida, n_t puede aproximarse, basándonos en el teorema central del límite, a una distribución normal de media μ y desviación estándar σ .

Por último, sólo cabe señalar que la técnica de estima de la posición a partir de una medida que utiliza este algoritmo es la de *lateration*, explicada en la capítulo anterior y que está dentro de la familia de las técnicas de Triangulación.

A continuación pasamos a detallar el Algoritmo basado en la Energía acústica.

Algoritmo basado en la Energía acústica

El algoritmo de localización basado en la energía acústica determina la posición del objeto, mediante los valores de energía acústica captados por una red de sensores cuya ubicación es conocida. La señal acústica es emitida por el objeto a localizar y llegará con una intensidad u otra a los sensores dependiendo de la distancia de estos al objeto. Por tanto, el modelo de medida está basado en la relación entre el nivel de energía recibida y la distancia entre objeto y sensor. La señal emitida por el objeto, es medida instantáneamente por varios sensores, por ello es posible la utilización de la técnica de *lateration* para la estima de la posición. A partir de ahora, el superíndice i hará referencia al sensor i de los N disponibles.

Adicionalmente, si se asume que $n_t^{(i)}$ es una variable aleatoria normal independiente e idénticamente distribuida (i.i.d) con media $\mu^{(i)} > 0$ y varianza $\sigma^{(i)}$ conocidas, cada valor de energía medido $z_t^{(i)}$ será, también, una variable aleatoria normal i.i.d con la siguiente función de densidad de probabilidad:

$$N \left(g^{(i)} \cdot \frac{s_t}{|\underline{r}_t - \underline{r}^{(i)}|^2} + \mu^{(i)}, \sigma^{(i)2} \right) \quad (2.11)$$

Por tanto, la función de probabilidad conjunta puede expresarse de la siguiente manera:

$$l(\underline{z}_t, \underline{r}_t) = f(z_t^{(1)}, \dots, z_t^{(N)} | \sigma^2) \propto \exp \left\{ -\frac{1}{2} \sum_{i=1}^N \left\{ \frac{\left[z_t^{(i)} - \mu^{(i)} - \frac{g^{(i)} \cdot s_t}{|\underline{r}_t - \underline{r}^{(i)}|^2} \right]^2}{\sigma^{(i)2}} \right\} \right\} \quad (2.12)$$

Tomando logaritmos obtenemos la función logarítmica de probabilidad:

$$L(\underline{z}_t, \underline{r}_t) \propto \sum_{i=1}^N \left\{ \frac{\left[z_t^{(i)} - \mu^{(i)} - \frac{g^{(i)} \cdot s_t}{|\underline{r}_t - \underline{r}^{(i)}|^2} \right]^2}{\sigma^{(i)2}} \right\} \quad (2.13)$$

Conocidos $z_t^{(i)}$, $g^{(i)}$, $\underline{r}^{(i)}$, $\mu^{(i)}$, $\sigma^{(i)2}$, el objetivo de la estimación de máxima probabilidad es encontrar el valor de la energía emitida por la fuente s_t y la posición de la misma \underline{r}_t que maximiza la función de probabilidad (2.12) o, lo que es lo mismo, que minimiza la función de probabilidad logarítmica (2.13).

En las fórmulas anteriormente expuestas observamos cómo la función logarítmica de probabilidad depende tanto de la posición del objeto, \underline{r}_t , como de la energía emitida, s_t . Para que dicha función sea independiente de s_t , calcularemos la relación entre las medidas de energía tomadas por pares de sensores, de tal manera que, si nos encontramos en un escenario ausente de ruido, la dependencia con s_t desaparece.

Aproximando el término de ruido $n_t^{(i)}$ en la ecuación (2.10) por la media $\mu^{(i)}$, podemos calcular el ratio de energía $\kappa_t^{(ij)}$ de los sensores i y j :

$$\kappa_t^{(ij)} = \left(\frac{(z_t^{(i)} - \mu^{(i)}) / (z_t^{(j)} - \mu^{(j)})}{g^{(i)} / g^{(j)}} \right)^{-\frac{1}{2}} = \frac{|\underline{r}_t - \underline{r}^{(i)}|}{|\underline{r}_t - \underline{r}^{(j)}|} \quad (2.14)$$

Para $0 < \kappa_t^{(ij)} \neq 1$, todos los posibles valores de \underline{r}_t que satisfacen (2.14) deben estar en la hipersfera de dimensión d asociada a los sensores i y j , descrita por la siguiente ecuación:

$$\left| \underline{r}_t - \underline{c}_t^{(ij)} \right|^2 = \rho_t^{(ij)2} \quad (2.15)$$

donde $\underline{c}_t^{(ij)}$ es el centro y $\rho_t^{(ij)}$ el radio:

$$\underline{c}_t^{(ij)} = \frac{\underline{r}^{(i)} - \kappa_t^{(ij)2} \underline{r}^{(j)}}{1 - \kappa_t^{(ij)2}} \quad \rho_t^{(ij)} = \frac{\kappa_t^{(ij)} |\underline{r}^{(i)} - \underline{r}^{(j)}|}{1 - \kappa_t^{(ij)}} \quad (2.16)$$

Cuando $\kappa_t^{(ij)} \rightarrow 1$ (caso límite), la solución de (2.14) forma un hiperplano entre $\underline{r}^{(i)}$ y $\underline{r}^{(j)}$

$$\underline{r}_t \cdot \underline{\gamma}^{(ij)} = \varsigma^{(ij)} \quad (2.17)$$




Figura 2.2: *Situados dos sensores en $(-1, 0)$ y $(1, 0)$, se muestran los círculos de localización correspondientes a diferentes valores de κ ($0.4, 0.6, 0.8$)*

donde

$$\underline{\gamma}^{(ij)} = \underline{r}^{(i)} - \underline{r}^{(j)} \quad \zeta^{(ij)} = \frac{|\underline{r}^{(i)}|^2 - |\underline{r}^{(j)}|^2}{2} \quad (2.18)$$

Cuando la dimensión de la hiperesfera, d es 2, se trata de un círculo. Cuando $d = 3$, es una esfera. La Figura 2.2 muestra múltiples ejemplos de hiperesferas de $d = 2$ correspondientes a diferentes valores de $\kappa_t^{(ij)} < 1$.

Usando el ratio de la energía medida por un par de sensores, somos capaces de limitar la localización del blanco a la hiperesfera formada. Si existen varios sensores que captan energía en un instante, por cada par de ellos podremos formar una hiperesfera, de tal forma que la intersección de todas las hiperesferas formadas nos dará la posición exacta del objeto (técnica de *lateration*).

Suponiendo que N sensores acústicos detectan la señal emitida por el blanco en el mismo intervalo de tiempo, se podrán calcular $N(N - 1)/2$ pares de ratios de energía. De tal forma, que utilizando M de esos ratios de energía debemos estimar la localización del blanco \underline{r}_t en dicho intervalo de tiempo. Este problema se reduce a una estimación no lineal por mínimos cuadrados cuya función de coste tiene

la siguiente forma:

$$J(\underline{r}_t) = \sum_{m=1}^{M_1} \left| \left\| \underline{r}_t - \underline{c}_t^{(m)} \right\| - \rho_t^{(m)} \right|^2 + \sum_{n=1}^{M_2} \left| \underline{\gamma}^{(n)'} \underline{r}_t - \varsigma^{(n)} \right|^2$$

$$M_1 + M_2 = M \quad (2.19)$$

donde m y n son índices de ratios de energía calculados entre diferentes pares de sensores, M_1 es el número de hiperesferas y M_2 es el número de hiperplanos.

La función de coste, en 2.19, no es lineal con respecto a la posición del blanco \underline{r}_t . Para encontrar una formulación lineal por mínimos cuadrados, sin imponer ninguna restricción, de la función de coste, consideramos dos hiperesferas formadas por los pares de sensores $(i, 0)$ y $(j, 0)$ que, según (2.15), se ajustan a las siguientes ecuaciones:

$$\left| \underline{r}_t - \underline{c}_t^{(i0)} \right|^2 = \rho_t^{(i0)2} \quad \left| \underline{r}_t - \underline{c}_t^{(j0)} \right|^2 = \rho_t^{(j0)2} \quad (2.20)$$

Si restamos ambos términos de las ecuaciones anteriores y cancelamos el término $|\underline{r}_t|^2$ obtenemos:

$$2 \left(\underline{c}_t^{(i0)} - \underline{c}_t^{(j0)} \right) \underline{r}_t = \left(\underline{c}_t^{(i0)2} - \rho_t^{(i0)2} \right) - \left(\underline{c}_t^{(j0)2} - \rho_t^{(j0)2} \right) \quad (2.21)$$

Si sustituimos $\underline{c}_t^{(i0)}$, $\rho_t^{(i0)}$, $\underline{c}_t^{(j0)}$ y $\rho_t^{(j0)2}$ por sus correspondientes definiciones, obtenemos la ecuación lineal de un hiperplano:

$$\underline{u}_t^{(ij)} \underline{r}_t = \theta_t^{(ij)} \quad (2.22)$$

donde

$$\underline{u}_t^{(ij)} = \frac{2\underline{r}^{(i)}}{1 - \kappa_t^{(i1)2}} - \frac{2\underline{r}^{(j)}}{1 - \kappa_t^{(j1)2}} \quad \theta_t^{(ij)} = \frac{|\underline{r}^{(i)}|^2}{1 - \kappa_t^{(i1)2}} - \frac{|\underline{r}^{(j)}|^2}{1 - \kappa_t^{(j1)2}} \quad (2.23)$$

Entonces, la función de coste, (2.19), puede ser reemplazada por la siguiente función lineal por mínimos cuadrados sin restricciones:

$$J_{lineal}(\underline{r}_t) = \sum_{m=1}^{M_1} \left| \underline{u}_t^{(m)'} \underline{r}_t - \theta_t^{(m)} \right|^2 + \sum_{n=1}^{M_2} \left| \underline{\gamma}^{(n)'} \underline{r}_t - \varsigma^{(n)} \right|^2 \quad (2.24)$$

En [1] se demuestra que, en 2D, se necesitan al menos tres hiperesferas, es decir, cuatro sensores con una medida simultánea de la energía, para tener un único punto de intersección, y, por tanto, la localización del blanco. La figura 2.3 muestra la simulación de la localización de un blanco en 2D utilizando cuatro sensores y tres ratios de energía.




Figura 2.3: Localización de un blanco usando cuatro sensores.

2.2. Algoritmos de seguimiento

El problema de seguimiento de un objeto en movimiento es equivalente al problema de estimación del estado de un sistema cuando dicho estado viene representado por su correspondiente vector, \underline{x}_t .

El seguimiento se diferencia de la localización debido a su naturaleza secuencial o recursiva. Dicha naturaleza proviene del hecho de que para la estima del vector de estado, en un instante, se parte del conocimiento del estado en el instante inmediatamente anterior. Esto se consigue gracias al modelo del sistema (2.2) que relaciona el estado en ambos instantes de tiempo. Por otra parte, la estima realizada es mejorada gracias a la recepción de una nueva medida del blanco que ampliará el conocimiento sobre el estado a través del modelo de medida (2.3).

Los algoritmos de seguimiento basan su funcionamiento en el Teorema de Bayes:

$$p(\underline{x}_t | \underline{z}_t) = \frac{p(\underline{z}_t | \underline{x}_t) p(\underline{x}_t)}{p(\underline{z}_t)} \quad (2.25)$$

Además, asumen las siguientes condiciones de independencia:

- Condicionada a \underline{x}_t , la medida \underline{z}_t es independiente de la medida anterior \underline{z}_{t-1} .
- Condicionada a \underline{x}_{t-1} , el nuevo estado del blanco \underline{x}_t también es independiente de la medida anterior \underline{z}_{t-1} .

De acuerdo con estas suposiciones,

$$p(\underline{x}_t | \underline{z}_t) \propto p(\underline{z}_t | \underline{x}_t) p(\underline{x}_t | \underline{z}_{t-1}) \quad (2.26)$$

En la ecuación (2.26) podemos distinguir las dos etapas de que constan los algoritmos de seguimiento: predicción y actualización.

Suponemos disponible la densidad de probabilidad a posteriori en el instante anterior $p(\underline{x}_{t-1} | \underline{z}_{t-1})$. La etapa de predicción utiliza dicha densidad junto con el modelo probabilístico del sistema $p(\underline{x}_t | \underline{x}_{t-1})$ para obtener la densidad de probabilidad a priori $p(\underline{x}_t | \underline{z}_{t-1})$:

$$p(\underline{x}_t | \underline{z}_{t-1}) = \int p(\underline{x}_t | \underline{x}_{t-1}) p(\underline{x}_{t-1} | \underline{z}_{t-1}) d\underline{x}_{t-1} \quad (2.27)$$

Una vez obtenida la densidad de probabilidad a priori, $p(\underline{x}_t | \underline{z}_{t-1})$, tras la etapa de predicción, es posible, realizar la actualización (según ecuación (2.26)) sabiendo que en instante t tendremos disponible una nueva medida, \underline{z}_t . Para dicha actualización será necesaria el modelo probabilístico de medida, $p(\underline{z}_t | \underline{x}_t)$. Tras esta etapa habremos obtenido la densidad de probabilidad a posteriori buscada, $p(\underline{x}_t | \underline{z}_t)$.




Figura 2.4: Ejemplo de $p(\underline{x}_t | \underline{x}_{t-1})$ considerando la velocidad uniformemente distribuida entre $[0, v_{max}]$

Las ecuaciones (2.26) y (2.27) forman la base de la solución óptima Bayesiana[9]. A modo de aclaración vamos a describir las diferentes distribuciones de probabilidad que intervienen en dicha solución:

- $p(\underline{x}_{t-1} | \underline{z}_{t-1})$ es la distribución de probabilidad a posteriori calculada en el instante anterior.
- $p(\underline{x}_t | \underline{x}_{t-1})$ es la distribución de probabilidad del vector de estado en el instante actual condicionada al vector de estado en el instante anterior. Es decir, nos da una idea de cómo de probable es que esté el blanco en una determinada posición sabiendo su posición anterior. Por tanto, esta distribución de probabilidad está muy relacionada con la dinámica del objeto en movimiento. La figura 2.4 muestra un ejemplo de esta distribución.
- $p(\underline{z}_t | \underline{x}_t)$ es la distribución de probabilidad de la observación dada la posición del objetivo. Esta probabilidad está íntimamente relacionada con la naturaleza del sensor. En [11], realizan el desarrollo de la expresión de esta distribución de probabilidad para los sensores de amplitud acústica. La siguiente figura muestra la forma de la distribución para estos sensores. Como podemos observar la zona de mayor probabilidad formará un anillo alrededor del sensor. La distancia de dicho anillo al sensor dependerá la intensidad de energía acústica medida por el sensor. El ruido hará que el anillo tenga un mayor o menor grosor.

Esta propagación recursiva de la densidad a posteriori es únicamente un resultado conceptual, dado que, en general, no se puede determinar analíticamente [9].




Figura 2.5: Representación de la densidad de probabilidad $p(\underline{z}_t|\underline{x}_t)$ para sensores de amplitud acústica.

Al igual que hicimos con los algoritmos de localización, hemos realizado una clasificación de los algoritmos de seguimiento en función de la forma en que resuelven el problema. Por un lado, tenemos los algoritmos *Tipo I*, que no asumen ninguna distribución estadística de los datos y realizan aproximaciones numéricas de la solución óptima Bayesiana, obteniendo, finalmente, una estima de la PDF a posteriori, $\hat{p}(\underline{x}_t|\underline{z}_t)$. Por otra parte, tenemos los algoritmos de seguimiento *Tipo II* que, asumiendo una distribución normal de los datos, dejan de trabajar con funciones de probabilidad para trabajar con parámetros de las mismas, obteniendo de forma analítica la solución óptima Bayesiana. Es decir, estiman directamente el vector de estado $\hat{\underline{x}}_t$.

2.2.1. Algoritmos de seguimiento *Tipo I*: Estiman $\hat{p}(\underline{x}_t|\underline{z}_t)$

El resultado de los algoritmos de seguimiento *Tipo I* será la distribución de probabilidad a posteriori del estado del blanco $p(\underline{x}_t|\underline{z}_t)$, a partir de la cual se calculará la estimación del estado $\hat{\underline{x}}_t$, según la ecuación (2.4).

Como hemos visto con anterioridad, este tipo de algoritmos no asumen la distribución estadística de los datos, lo cual hace imposible determinar analíticamente la solución óptima Bayesiana. Para resolver el problema, estos algoritmos realizan una aproximación numérica de la PDF a posteriori y le aplican el filtrado bayesiano. El Filtro de Partículas, es un ejemplo de los algoritmos de seguimiento *Tipo II*.

Filtro de partículas

La idea clave del Filtro de Partículas [9][12][13] es la representación de la distribución de probabilidad a posteriori, $p(\underline{x}_t|\underline{z}_t)$, mediante un conjunto de muestras discretas con pesos asociados, como ya explicamos en el caso de la localización. En el caso del seguimiento, debemos aprovechar el conocimiento de la representación de dicha densidad en el instante anterior, para obtener un algoritmo secuencial que aproxime la solución óptima de Bayes:

$$\left\{ \underline{x}_{t-1}^{(i)}, w_{t-1}^{(i)} \right\}_{i=1}^N \quad (2.28)$$

$$w_{t-1}^{(i)} \propto p(\underline{x}_{t-1}^{(i)}|\underline{z}_{t-1}) \quad (2.29)$$

donde $\underline{x}_{t-1}^{(i)}$ representa la muestra i de la densidad de probabilidad a posteriori $p(\underline{x}_{t-1}|\underline{z}_{t-1})$ y es denominada partícula. $w_{t-1}^{(i)}$ es el peso asociado a la muestra $\underline{x}_{t-1}^{(i)}$, y N es el número de partículas. Si $N \rightarrow \infty$, este algoritmo deja de ser una aproximación para convertirse en la solución óptima Bayesiana.

Partiendo de las partículas en el instante anterior, podemos definir las dos etapas de las que consta el algoritmo:

- **Etapas de predicción.** Gracias al modelo del sistema, (2.2), que describe la evolución del estado del blanco con el tiempo, es posible predecir las partículas en el siguiente instante:

$$\underline{x}_t^{(i)} = f(\underline{x}_{t-1}^{(i)}, \underline{v}_{t-1}) \quad (2.30)$$

El resultado de esta etapa sería el nuevo conjunto de muestras $\left\{ \underline{x}_t^{(i)} \right\}_{i=1}^N$.

- **Etapas de actualización.** Tras la recepción de una nueva medida, \underline{z}_t , podríamos utilizar el modelo de medida (2.3), para actualizar las partículas. Dicha actualización se lleva a cabo en dos fases. La primera, denominada “Muestreo secuencial enfatizado”, calcula los pesos de las nuevas partículas, $\left\{ w_t^{(i)} \right\}_{i=1}^N$, partiendo de los pesos de las partículas del instante anterior $\left\{ w_{t-1}^{(i)} \right\}_{i=1}^N$, y del conocimiento de una nueva medida \underline{z}_t y del modelo probabilístico de medida $p(\underline{z}_t|\underline{x}_t)$. Para obtener la ecuación de actualización de pesos partimos de la siguiente expresión:

$$\begin{aligned} p(\underline{x}_t|\underline{z}_t) &\propto p(\underline{z}_t|\underline{x}_t) p(\underline{x}_t|\underline{z}_{t-1}) \\ &\propto p(\underline{z}_t|\underline{x}_t) p(\underline{x}_t|\underline{x}_{t-1}) p(\underline{x}_{t-1}|\underline{z}_{t-1}) \end{aligned} \quad (2.31)$$

Si en la definición de peso (2.29) incluimos (2.31), tendremos:

$$\begin{aligned}
 w_t^{(i)} &\propto p(\underline{x}_t^{(i)} | \underline{z}_t) \\
 &\propto p(\underline{z}_t | \underline{x}_t^{(i)}) p(\underline{x}_t^{(i)} | \underline{x}_{t-1}^{(i)}) p(\underline{x}_{t-1}^{(i)} | \underline{z}_{t-1}) \\
 &\propto w_{t-1}^{(i)} \left[p(\underline{z}_t | \underline{x}_t^{(i)}) p(\underline{x}_t^{(i)} | \underline{x}_{t-1}^{(i)}) \right]
 \end{aligned} \tag{2.32}$$

En la fase de muestreo secuencial enfatizado aparece el inconveniente de la degeneración de los pesos (disminución del número de muestras que contribuyen a aproximar la distribución debido a la pérdida de valor de sus respectivos pesos). Por este motivo, en la etapa de actualización es posible que sea necesario incluir la fase de “Remuestreo”. Para saber si es necesaria dicha fase hay que calcular el tamaño efectivo de la muestra N_{ef} , que mide la degeneración de los pesos:

$$N_{ef} = \frac{1}{\sum_{i=1}^N (w_t^{(i)})^2} \tag{2.33}$$

donde $w_t^{(i)}$ son los pesos normalizados ($\sum_i^N w_t^{(i)} = 1$). Como idea intuitiva, N_{ef} estima el número de partículas “útiles” en el conjunto de muestras, entendiendo como útil, aquélla que contribuye significativamente a la aproximación de la distribución. Como necesariamente se debe cumplir que $1 \leq N_{ef} \leq N$, pueden alcanzarse los siguientes casos extremos:

- Si los pesos son uniformes, es decir, $w_t^{(i)} = \frac{1}{N} \forall i = \{1, \dots, N\}$, entonces $N_{ef} = N$.
- Si $\exists j \in \{1, \dots, N\} \mid w_t^{(j)} = 1$ y $w_t^{(i)} = 0 \forall i \neq j$, entonces $N_{ef} = 1$.

Por lo tanto, si $N_{ef} \leq N_{umbral}^2$, se lleva a cabo la fase de remuestreo. Dicha fase da como resultado, a partir de la población $\{\underline{x}_t^{(i)*}, w_t^{(i)}\}_{i=1}^N$, un nuevo conjunto de partículas $\{\underline{x}_t^{(i)*}, 1/N\}_{i=1}^N$ con pesos uniformes. El nuevo conjunto de muestras aleatorias $\{\underline{x}_t^{(i)*}\}_{i=1}^N$ se genera remuestreando y reemplazando el conjunto de muestras $\{\underline{x}_t^{(i)}\}_{i=1}^N$, de tal forma que la probabilidad de elegir a una partícula está directamente relacionada con el valor de su peso, es decir, $p(\underline{x}_t^{(i)*} | \underline{x}_t^{(j)}) \propto w_t^{(j)}$.

Finalmente, tras la aplicación del Filtro de Partículas obtendremos una aproximación de la distribución de probabilidad a posteriori dada por la siguiente expresión:

$$p(\underline{x}_t | \underline{z}_t) \approx \sum_{i=1}^N \frac{1}{N} \delta(\underline{x}_t - \underline{x}_t^{(i)*}) \tag{2.34}$$

²Donde N_{umbral} es un parámetro experimental a partir del cual se considera que la degeneración de la población de partículas requiere la participación de una fase de remuestreo.

2.2.2. Algoritmos de seguimiento *Tipo II*: Estiman $\hat{\underline{x}}_t$

El resultado de los algoritmos de seguimiento *Tipo II* es directamente la estima del vector de estado $\hat{\underline{x}}_t$. Usualmente estos algoritmos requieren que los datos se ajusten a una distribución normal.

La hipótesis de distribución normal de los datos implica que las diferentes funciones de densidad de probabilidad que intervienen en el filtrado bayesiano se aproximen a distribuciones gaussianas, y pueda trabajarse con sus dos parámetros característicos: media y covarianza

$$p(\underline{x}_{t-1}|\underline{z}_{t-1}) \approx N(\hat{\underline{x}}_{t-1}, \underline{P}_{\underline{x}_{t-1}}) \quad (2.35)$$

$$p(\underline{x}_t|\underline{z}_{t-1}) \approx N(\hat{\underline{x}}_t^-, \underline{P}_{\underline{x}_t^-}) \quad (2.36)$$

$$p(\underline{x}_t|\underline{z}_t) \approx N(\hat{\underline{x}}_t, \underline{P}_{\underline{x}_t}) \quad (2.37)$$

$$p(\underline{z}_t|\underline{x}_t) \approx N(\hat{\underline{z}}_t, \underline{P}_{\underline{z}_t}) \quad (2.38)$$

A continuación, se explican con mas detalle tres algoritmos de este tipo.

Kalman Filter

El *Kalman Filter* (KF) [9][14][15] asume, además de la gaussianidad de las diferentes funciones de probabilidad (2.38), las siguientes premisas:

- Las variables \underline{v}_{t-1} y \underline{n}_t están distribuidas según gaussianas de parámetros conocidos.
- $f(\underline{x}_{t-1}, \underline{v}_{t-1})$ es conocida y lineal con respecto a \underline{x}_{t-1} y \underline{v}_{t-1} .
- $h(\underline{x}_t, \underline{n}_t)$ es una función lineal conocida de \underline{x}_t y \underline{n}_t .

Entonces, el modelo de espacio de estados, (2.2) y (2.3), puede reescribirse de la siguiente manera:

$$\underline{x}_t = \underline{F} \underline{x}_{t-1} + \underline{v}_{t-1} \quad (2.39)$$

$$\underline{z}_t = \underline{H} \underline{x}_t + \underline{n}_t \quad (2.40)$$

\underline{F} y \underline{H} son matrices conocidas que definen las funciones lineales. Las covarianzas de \underline{v}_{t-1} y \underline{n}_t (considerando que ambas tienen media cero y son estadísticamente independientes) son, respectivamente, \underline{Q} y \underline{R} .

Partiendo del conocimiento de los parámetros $\hat{\underline{x}}_{t-1}$ y $\underline{P}_{\underline{x}_{t-1}}$ de la densidad de probabilidad a posteriori del instante anterior y derivando de las ecuaciones (2.26) y (2.27), pueden formular las diferentes etapas del algoritmo KF:

- **Etapa de predicción.** Partiendo de los modelos de estado y de medida, es posible predecir el estado y la medida, respectivamente, conocidos los parámetros $\hat{\underline{x}}_{t-1}$ y $\underline{P}_{\underline{x}_{t-1}}$, en el instante anterior.

Predicción del estado:

$$\hat{\underline{x}}_t^- = \underline{F} \hat{\underline{x}}_{t-1} \quad (2.41)$$

$$\underline{P}_{\underline{x}_t^-} = \underline{F} \underline{P}_{\underline{x}_{t-1}} \underline{F}^T + \underline{Q} \quad (2.42)$$

Predicción de la medida:

$$\hat{\underline{z}}_t = \underline{H} \hat{\underline{x}}_t^- \quad (2.43)$$

$$\underline{P}_{\underline{z}_t} = \underline{H} \underline{P}_{\underline{x}_t^-} \underline{H}^T + \underline{R} \quad (2.44)$$

siendo \underline{Q} y \underline{R} las covarianzas de \underline{v}_{t-1} y \underline{n}_t , respectivamente, considerando que ambas tienen media cero y son estadísticamente independientes.

- **Etapa de actualización.** Tras la llegada de una nueva medida \underline{z}_t , es posible actualizar el estado estimado en la etapa anterior.

Cálculo covarianza de la predicción del estado dada la nueva medida:

$$\underline{P}_{\underline{x}_t^- | \underline{z}_t} = \underline{P}_{\underline{x}_t^-} \underline{H}^T \quad (2.45)$$

Cálculo de la ganancia de Kalman:

$$\underline{K}_t = \frac{\underline{P}_{\underline{x}_t^- | \underline{z}_t}}{\underline{P}_{\underline{z}_t}} = \underline{P}_{\underline{x}_t^-} \underline{H}^T \left(\underline{H} \underline{P}_{\underline{x}_t^-} \underline{H}^T + \underline{R} \right)^{-1} \quad (2.46)$$

Actualización del estado:

$$\hat{\underline{x}}_t = \hat{\underline{x}}_t^- + \underline{K}_t (\underline{z}_t - \hat{\underline{z}}_t) \quad (2.47)$$

$$\underline{P}_{\underline{x}_t} = \underline{P}_{\underline{x}_t^-} - \underline{K}_t \underline{P}_{\underline{x}_t^-} \underline{K}_t^T = (I - \underline{K}_t \underline{H}) \underline{P}_{\underline{x}_t^-} \quad (2.48)$$

Tras una iteración del **KF** habremos obtenido la estima del vector de estado en el instante t : $\hat{\underline{x}}_t$.

Extended Kalman Filter

El *Extended Kalman Filter* (**EKF**) [9][14][15] surge como posible solución al **KF** cuando no se cumple la premisa de linealidad, es decir, cuando el modelo del sistema, (2.2), y el modelo de medida, (2.3),

no pueden reescribirse como 2.39 y (2.40). El algoritmo **EKF**, soluciona dicho problema realizando una linealización local.

Las diferentes etapas de las que consta el algoritmo pueden formularse de la siguiente manera:

- **Etapas de linealización.** Se realiza una linealización local de las funciones no lineales utilizando las siguientes matrices Jacobianas de derivadas parciales:

$$\underline{\hat{F}}_{[i,j]} = \frac{\partial f_{[i]}}{\partial x_{[j]}}(\hat{x}_{t-1}) \quad (2.49)$$

$$\underline{\hat{H}}_{[i,j]} = \frac{\partial h_{[i]}}{\partial x_{[j]}}(\hat{x}_t^-) \quad (2.50)$$

- **Etapas de predicción.** Partiendo del conocimiento de los parámetros \hat{x}_{t-1} y $\underline{P}_{x_{t-1}}$ de la densidad de probabilidad a posteriori del instante anterior, se predice el estado y la medida en el instante siguiente.

Predicción del estado:

$$\hat{x}_t^- = f(\hat{x}_{t-1}, v_t) \quad (2.51)$$

$$\underline{P}_{x_t^-} = \underline{\hat{F}} \underline{P}_{x_{t-1}} \underline{\hat{F}}^T + \underline{Q} \quad (2.52)$$

Predicción de la medida:

$$\hat{z}_t = h(\hat{x}_t^-) \quad (2.53)$$

$$\underline{P}_{z_t} = \underline{\hat{H}} \underline{P}_{x_t^-} \underline{\hat{H}}^T + \underline{R} \quad (2.54)$$

siendo \underline{Q} y \underline{R} las covarianzas de v_{t-1} y n_t , respectivamente, considerando que ambas tienen media cero y son estadísticamente independientes.

- **Etapas de actualización.** Tras la llegada de una nueva medida z_t , es posible actualizar el estado estimado en la etapa anterior.

Cálculo covarianza de la predicción del estado dada la nueva medida:

$$\underline{P}_{x_t^-|z_t} = \underline{P}_{x_t^-} \underline{\hat{H}}^T \quad (2.55)$$

Cálculo de la ganancia de Kalman:

$$\underline{K}_t = \frac{\underline{P}_{x_t^-|z_t}}{\underline{P}_{z_t}} = \underline{P}_{x_t^-} \underline{\hat{H}}^T \left(\underline{\hat{H}} \underline{P}_{x_t^-} \underline{\hat{H}}^T + \underline{R} \right)^{-1} \quad (2.56)$$

Actualización del estado:

$$\hat{\underline{x}}_t = \hat{\underline{x}}_t^- + \underline{K}_t (z_t - \hat{z}_t) \quad (2.57)$$

$$\underline{P}_{\underline{x}_t} = \underline{P}_{\underline{x}_t^-} - \underline{K}_t \underline{P}_{z_t} \underline{K}_t^T = (I - \underline{K}_t \hat{\underline{H}}) \underline{P}_{\underline{x}_t^-} \quad (2.58)$$

donde $f(\cdot)$ y $h(\cdot)$ son las funciones no lineales, y $\hat{\underline{F}}$ y $\hat{\underline{H}}$ son las linealizaciones locales de tales funciones.

Tras una iteración del algoritmo **EKF** habremos obtenido la estima del vector de estado en el instante t : $\hat{\underline{x}}_t$.

Unscented Kalman Filter

El *Unscented Kalman Filter* (**UKF**) [16][17][18][19] es otra alternativa al filtro de Kalman, cuando las funciones $f(\cdot)$ y $h(\cdot)$ no son lineales. La base de este algoritmo es la transformación denominada *unscented transformation* (**UT**), método para calcular los estadísticos de una variable aleatoria que sufre una transformación no lineal.

Dada una variable aleatoria gaussiana $n - dimensional$, de media y covarianza conocidas, la **UT** obtiene $2n + 1$ puntos (denominados puntos sigma), con sus respectivos pesos, que capturan completamente la verdadera media y covarianza de dicha variable gaussiana.

El **UKF**, al igual que el **KF** y el **EKF**, considera que la $p(\underline{x}_t | \underline{z}_t)$ se distribuye según una gaussiana en cualquier instante de tiempo.

Por tanto, conocidas la media, $\hat{\underline{x}}_{t-1}$, y la covarianza, $\underline{P}_{\underline{x}_{t-1}}$, de $p(\underline{x}_{t-1} | \underline{z}_{t-1})$ podremos obtener sus correspondientes puntos sigma según la **UT**. La novedad que introduce el **UKF** es que son dichos puntos sigma los que se introduce en las etapas de predicción y actualización típicas del filtrado de Kalman, obteniendo, finalmente, los puntos sigma que representan completamente la media, $\hat{\underline{x}}_t$, y la covarianza, $\underline{P}_{\underline{x}_t}$, de la densidad de probabilidad a posteriori, $p(\underline{x}_t | \underline{z}_t)$.

Partiendo del conocimiento de los parámetros $\hat{\underline{x}}_{t-1}$ y $\underline{P}_{\underline{x}_{t-1}}$ de la densidad de probabilidad a posteriori del instante anterior, las diferentes etapas del algoritmo **UKF** son gobernadas por las siguientes ecuaciones:

- **Etapas de UT.** Cálculo de los puntos sigma que representan la densidad de probabilidad a

posteriori del instante anterior.

$$\begin{aligned}
 \chi_{t-1}^{(0)} &= \hat{\underline{x}}_{t-1} \\
 \chi_{t-1}^{(i)} &= \hat{\underline{x}}_{t-1} + \left(\sqrt{(n+\lambda) \underline{\underline{P}}_{\underline{x}_{t-1}}} \right)_i \quad i = 1, \dots, n \\
 \chi_{t-1}^{(i)} &= \hat{\underline{x}}_{t-1} - \left(\sqrt{(n+\lambda) \underline{\underline{P}}_{\underline{x}_{t-1}}} \right)_i \quad i = n+1, \dots, 2n \\
 W_{t-1}^{m(0)} &= \frac{\lambda}{n+\lambda} \\
 W_{t-1}^{p(0)} &= \frac{\lambda}{n+\lambda} + (1 - \alpha^2 + \beta) \\
 W_{t-1}^{m(i)} &= W_{t-1}^{p(i)} = \frac{1}{2(n+\lambda)} \quad i = 1, \dots, 2n
 \end{aligned} \tag{2.59}$$

donde $\lambda = \alpha^2(L + \kappa) - L$ es el parámetro escalado; α determina la propagación de los puntos sigma y normalmente es un valor pequeño, por ejemplo, 10^{-3} ; κ es el parámetro de escalado secundario, cuyo valor suele ser nulo; y β se utiliza para incorporar el conocimiento anterior de la distribución, y su valor óptimo para una distribución gaussiana es 2.

- **Etapas de predicción.** Predicción del estado y de la medida partiendo de los puntos sigma que representa la **PDF** a posteriori del instante anterior.

Predicción del estado:

$$\chi_t^{(i)} = f(\chi_{t-1}^{(i)}, v_{t-1}) \tag{2.60}$$

$$\hat{\underline{x}}_t^- = \sum_{i=0}^{2n} W_{t-1}^{m(i)} \chi_t^{(i)} \tag{2.61}$$

$$\underline{\underline{P}}_{\underline{x}_t}^- = \sum_{i=0}^{2n} W_{t-1}^{p(i)} (\chi_t^{(i)} - \hat{\underline{x}}_t^-)(\chi_t^{(i)} - \hat{\underline{x}}_t^-)^T + \underline{\underline{Q}} \tag{2.62}$$

Predicción de la medida:

$$Z_t^{(i)} = h(\chi_t^{(i)}) \tag{2.63}$$

$$\hat{\underline{z}}_t = \sum_{i=0}^{2n} W_{t-1}^{m(i)} Z_t^{(i)} \tag{2.64}$$

$$\underline{\underline{P}}_{\underline{z}_t} = \sum_{i=0}^{2n} W_{t-1}^{p(i)} (Z_t^{(i)} - \hat{\underline{z}}_t)(Z_t^{(i)} - \hat{\underline{z}}_t)^T + \underline{\underline{R}} \tag{2.65}$$

- **Etapas de actualización.** Tras la llegada de una nueva medida \underline{z}_t , es posible actualizar el estado estimado en la etapa anterior.

Cálculo covarianza de la predicción del estado dada la nueva medida:

$$\underline{\underline{P}}_{\underline{x}_t^-|\underline{z}_t} = \sum_{i=0}^{2n} W p_{t-1}^{(i)} (\chi_t^{(i)} - \hat{\underline{x}}_t^-) (Z_t^{(i)} - \hat{\underline{z}}_t)^T \quad (2.66)$$

Cálculo de la ganancia de Kalman:

$$\underline{\underline{K}}_t = \frac{\underline{\underline{P}}_{\underline{x}_t^-|\underline{z}_t}}{\underline{\underline{P}}_{\underline{z}_t}} \quad (2.67)$$

Actualización del estado:

$$\hat{\underline{x}}_t = \hat{\underline{x}}_t^- + \underline{\underline{K}}_t (z_t - \hat{\underline{z}}_t) \quad (2.68)$$

$$\underline{\underline{P}}_{\underline{x}_t} = \underline{\underline{P}}_{\underline{x}_t^-} - \underline{\underline{K}}_t \underline{\underline{P}}_{\underline{z}_t} \underline{\underline{K}}_t^T \quad (2.69)$$

Tras una iteración del algoritmo **UKF** habremos obtenido la estima del vector de estado en el instante t : $\hat{\underline{x}}_t$.

2.3. Resumen

A lo largo del capítulo hemos visto como el problema de la localización y el seguimiento es modelado mediante el modelo de espacio de estados, en el que las propiedades cinemáticas del blanco son introducidas en un vector que representa el estado del sistema/blanco, \underline{x}_t . Dicho modelado es completo con el modelo del sistema (2.2), que representa la relación entre los estados en instantes consecutivos y el modelo de medida, (2.3), que relaciona el estado actual con la medida sobre el sistema.

Hemos especificado la diferente información de que se dispone para cada uno de los problemas. En el caso de la localización únicamente se dispone de la medida realizada, mientras que el seguimiento cuenta, adicionalmente, con el conocimiento del estado en el instante anterior. Esto lleva a distinguir entre los algoritmos que resuelven un problema u otro. Además, en ambos casos, cabe destacar que existen, por un lado, ciertos algoritmos que no asumen ningún tipo de distribución estadística de los datos y que hemos denominado *Tipo I*, y, por otro lado, aquellos que asumen la distribución normal de los mismos, denominándolos *Tipo II*.

Entre los algoritmos de localización, se han descrito el Filtro de Partículas como ejemplo de algoritmo *Tipo I* y el algoritmo basado en la energía acústica como ejemplo de algoritmo *Tipo II*. Veremos con posterioridad cómo este último será el algoritmo elegido para nuestra solución ya que se supondrá que se dispone de sensores acústicos en nuestra red. En este sentido, cabe destacar el carácter no lineal del modelo de medida. Este hecho marcará la elección del resto de algoritmos utilizados.

Entre los algoritmos de seguimiento, se han descrito el Filtro de Partículas en su versión secuencial como ejemplo de algoritmo *Tipo I* y el filtro de Kalman, junto con alguna de sus variantes (**EKF** y **UKF**), como ejemplos de algoritmo *Tipo II*. En el siguiente capítulo veremos que para nuestra solución simplemente descartaremos el **KF** debido a su suposición de linealidad. Tanto el **FP** como el **EKF** y el **UKF** dan resultados satisfactorios.

SOLUCIÓN PROPIA PARA LA LOCALIZACIÓN Y EL SEGUIMIENTO

Nuestro objetivo consiste en estimar la trayectoria que va siguiendo un objeto en movimiento a través de un terreno monitorizado por una red inalámbrica de sensores distribuida.

Como vimos en el capítulo de Introducción, las redes de sensores poseen una serie de características (detección y procesamiento distribuido, comunicaciones inalámbricas, etc.) que hacen que esta tecnología sea ideal para alcanzar nuestro objetivo. Sin embargo, también poseen una serie de restricciones (energía finita, denso despliegue, nodos desatendidos, etc.) con las que habrá que contar a la hora de diseñar la red y el algoritmo que solucionará el problema de la estima de la trayectoria.

Para resolver nuestro objetivo, combinaremos y adaptaremos algunos de los algoritmos de localización y de seguimiento que estudiamos en el capítulo anterior. La combinación y adaptación se hará de tal manera que solventemos, del mejor modo posible, las restricciones de las redes de sensores y aprovechemos sus ventajas. Como vimos, estos algoritmos se basan en el modelo de espacio de estados. Es decir, su objetivo es estimar el vector de estado del sistema, que contiene las propiedades cinemáticas del blanco, utilizando el conocimiento del modelo del sistema (que representa el modelo de movimiento del blanco) y el modelo de medida (que nos dice como se relaciona la magnitud medida por el sensor con el vector de estado del blanco).

Por tanto, para el diseño de nuestra solución es fundamental modelar el movimiento del blanco (para tener bien definido el modelo del sistema) y definir el tipo de sensor que utilizaremos (para tener bien definido el modelo de medida). En las dos primeras secciones del presente capítulo trataremos ambas cuestiones, para posteriormente pasar a definir la solución empleada.

3.1. Descripción del blanco

Para poder aplicar los diferentes algoritmos de seguimiento que vimos con anterioridad, será necesario tener bien definido el tipo de movimiento que seguirá el blanco. En función de dicho movimiento, el vector de estado contendrá unas determinadas propiedades cinemáticas y el modelo del sistema tendrá una determinada forma.

Para describir el movimiento del blanco utilizaremos un modelo cinemático de segundo orden [20], denominado así ya que la segunda derivada de la posición, correspondiente a la aceleración, es tratada como ruido blanco. Por tanto, las únicas características cinemáticas incluidas en el vector de estado serán la posición y la velocidad.

$$\underline{x}_t = \begin{bmatrix} \underline{r}_t \\ \dot{\underline{r}}_t \end{bmatrix} \quad (3.1)$$

Dado que las observaciones (o medidas) son obtenidas en determinados instantes y la relación entre el estado de dos instantes consecutivos es lineal, el modelo será descrito, directamente, en tiempo discreto de la siguiente manera:

$$\underline{x}_{t+1} = \underline{F} \underline{x}_t + \underline{\Gamma} v_t \quad (3.2)$$

El escalar v_t será el valor, en el instante t , de un proceso ruidoso blanco, de media cero y desviación típica σ_v . Dicho valor se corresponde con la aceleración ya que influye de la misma manera al movimiento del blanco. En este modelo discreto, se asume que, durante todo el intervalo de tiempo t , la aceleración del blanco v_t es constante.

La matriz de transición, \underline{F} , es

$$\underline{F} = \begin{bmatrix} 1 & T \\ 0 & 1 \end{bmatrix} \quad (3.3)$$

siendo T el periodo de muestreo.

El vector de ganancia, que multiplica al proceso escalar ruidoso, viene dado por

$$\underline{\Gamma} = \begin{bmatrix} \frac{1}{2}T^2 \\ T \end{bmatrix} \quad (3.4)$$

La covarianza del proceso ruidoso multiplicado por la ganancia, $\underline{\Gamma}\sigma_t$, vendrá representado por la siguiente matriz

$$\underline{Q} = \begin{bmatrix} \frac{1}{4}T^4 & \frac{1}{2}T^3 \\ \frac{1}{2}T^3 & T^2 \end{bmatrix} \sigma_t^2 \quad (3.5)$$

De esta manera, el modelo del sistema queda perfectamente definido según el modelo cinemático de segundo orden descrito en (3.2). Tal modelo limita el tipo de blanco del que podremos estimar su trayectoria, a aquellos cuya velocidad varía de manera constante en cada intervalo de muestreo, siendo dicha variación independiente de un intervalo a otro.

Una vez fijado el modelo del sistema, sólo nos queda determinar el modelo de medida para tener completamente resuelto el modelo de espacio de estados en que se basa nuestra solución. A lo largo de la siguiente sección se hará una descripción tanto de la red de sensores con la que alcanzamos la solución, así como del tipo de sensores utilizado, lo cual nos especificará el modelo de medida.

3.2. Descripción de la red de sensores

Como hemos visto a lo largo de todo el proyecto, nuestra solución al problema de estima de la trayectoria que sigue un blanco está basada en redes inalámbricas de sensores distribuidas. Es necesario describir tanto los nodos que formarán nuestra red, como la forma en que se realizará el despliegue y el funcionamiento.

3.2.1. Nodos acústicos

Todos los nodos que forman nuestra red serán iguales en cuanto a equipamiento y constarán de los siguientes elementos:

- **Fuente de energía finita.** Lo que no llevará a intentar minimizar al máximo el gasto de dicho recurso.
- **Microcontrolador.** Que realizará el procesamiento de la información y el control de los diferentes dispositivos de que consta el nodo.
- **Memoria externa.** Que nos permitirá guardar información relevante para el procesado.
- **Conversor A/D.** Que digitalizará la señal analógica proporcionada por el sensor.
- **Transmisor/Receptor RF.** Que permitirá las comunicaciones entre los nodos.
- **Sensor.** Que nos proporciona medidas de la señal analógica de interés en instantes determinados.

El sensor es el elemento del nodo que nos definirá el modelo de medida. En el problema de la estima de la trayectoria, el tipo de sensor será elegido en función del tipo de señal analógica que es capaz de proporcionar el blanco y cuya medida pueda ser relacionada de alguna manera con su posición.

En nuestra solución suponemos que el blanco, al desplazarse por el terreno monitorizado, va emitiendo sonido. Es decir, el blanco es modelado como un emisor acústico, puntual y omnidireccional. Por tanto, el sensor acústico será el elegido para nuestros nodos. Dicho sensor será capaz de medir la intensidad con que le llega la señal acústica emitida por el objetivo. Sin embargo, no será la relación de la posición con dicha intensidad la que utilicemos como modelo de medida. Será utilizada la relación con la energía de la señal acústica. Sabiendo que dicha energía es inversamente proporcional al cuadrado de la distancia entre el sensor y el blanco, el modelo de medida puede ser formulado de la siguiente manera, suponiendo ausencia de ruido:

$$z_t^{(i)} = h(\underline{r}_t) \quad (3.6)$$

$$h(\underline{r}_t) = g^{(i)} \cdot \frac{s_t}{|\underline{r}_t - \underline{r}^{(i)}|^2} \quad (3.7)$$

siendo $z_t^{(i)}$ la energía acústica medida por el sensor i en el instante t , $g^{(i)}$ la ganancia de dicho sensor, s_t la energía emitida por el blanco, \underline{r}_t la posición del blanco en el instante de medida y $\underline{r}^{(i)}$ la posición del sensor i .

Una medida de energía es obtenida tras varios valores de intensidad de señal acústica captados por el sensor. De esta manera distinguiremos entre dos intervalos de tiempo que será necesario conocer y/o definir para el correcto funcionamiento del algoritmo:

- **Periodo de muestreo, T_m .** Es el tiempo transcurrido entre dos instantes de muestreo. Es decir, nos dice cada cuanto tiempo el sensor capta un valor de la señal acústica.
- **Periodo de energía, T_e .** Es el tiempo entre dos instantes de medida de energía. Para disponer de una medida óptima de energía son necesarias varias muestras de la señal. Por tanto,

$$T_e > T_m \quad (3.8)$$

La figura 3.1 realiza una buena representación de este concepto.

Por otro lado, existen dos conceptos relacionados con las características del nodo que habrá que tener muy en cuenta a la hora de desplegar la red.

- **Radio de cobertura acústica, R_{ca} .** Es el alcance máximo del sensor, es decir, la distancia máxima a la que el nodo sentirá el blanco. Dicha distancia dependerá del rango de medida del sensor y de la amplitud de la señal emitida por el blanco, según el modelo de medida.

$$E_m = \frac{E_b}{R_{ca}^2} \quad (3.9)$$




Figura 3.1: *Intervalos de muestreo y energía*

siendo E_m la energía mínima que es capaz de captar el sensor y E_b la energía emitida por el blanco.

- **Radio de alcance RF, R_{rf} .** Es la distancia máxima que alcanza el transmisor/receptor RF. En función de la colocación de los demás nodos de la red, dicha distancia determinará con cual de ellos es posible establecer comunicación y, por tanto, el intercambio de información.

Es fundamental conocer, tanto las características de los nodos que compondrán la red, como las del blanco a localizar para determinar la forma, más adecuada para alcanzar el objetivo, de despliegue y funcionamiento de la red.

3.2.2. Despliegue en cuadrícula

Como veremos con posterioridad, una de las ideas fundamentales de nuestra solución es la utilización de la energía medida por varios sensores simultáneamente. Es decir, en un instante de tiempo, varios sensores recibirán la señal emitida por el blanco y realizarán una medida de la energía. La medida de cada sensor será diferente dependiendo de su distancia al blanco.




Figura 3.2: El radio de cobertura acústica, R_{ca} , nos definirá la zona en la que un sensor es capaz de detectar la presencia de un blanco.




Figura 3.3: El radio de alcance RF , R_{rf} , nos definirá los nodos con los que se puede establecer comunicación.

La forma en que se despliegue la red será clave para conseguir que en cualquier instante de tiempo el blanco sea detectado por varios sensores simultáneamente. En nuestra solución hemos decidido un despliegue en cuadrícula dada su sencillez para cubrir el terreno de monitorización.

La distancia a la que se sitúan los nodos dependerá del radio de cobertura acústica de los mismos. Como muestra la figura 3.4, el conjunto de cuatro sensores forman un cuadrado. La diagonal de dicho cuadrado será igual al radio de cobertura acústica del nodo. De esta forma, se garantiza que todo punto del terreno monitorizado está dentro de la cobertura acústica de, al menos, cuatro nodos.




Figura 3.4: *Todo punto del terreno monitorizado estará cubierto por la cobertura de al menos 4 nodos.*

Por supuesto, este despliegue en cuadrícula no facilita únicamente la detección del blanco, si no que también facilita las comunicaciones de la red. Como explicaremos en la siguiente sección nuestra red posee un sistema de funcionamiento basado en líder, en el que un nodo se comunica con los sensores de su vecindad. Los vecinos con los que un nodo es capaz de comunicarse son aquellos situados dentro de su radio de alcance R_f . Habitualmente el radio de alcance R_f es mayor que el radio de cobertura acústica, por ello se ha elegido este último como parámetro restrictivo a la hora calcular la distancia a la que colocar los sensores. Si R_{rf} fuera menor que R_{ca} la diagonal del cuadrado formado por cuatro sensores sería igual a R_{rf} .

3.2.3. Funcionamiento basado en líder

El esquema basado en líder es un esquema de funcionamiento que aprovecha el carácter distribuido de las redes inalámbricas de sensores. No existe un nodo central que se encargue de recibir y procesar

toda la información de la red, sino que, de forma distribuida, la propia red, de manera autónoma, va eligiendo un líder que va variando con el tiempo. Cualquier nodo de la red puede llegar a ser líder en un momento determinado. La elección del líder se realiza en función de alguna característica que mejore la obtención del objetivo.

En nuestro caso, es la energía acústica, la característica que servirá para elegir al líder ya que a mayor energía medida por un nodo, menor distancia de dicho nodo al blanco. Por tanto, el líder será el nodo con mayor energía acústica medida. A la hora de diseñar el proceso de elección del líder es




Figura 3.5: *El nodo líder será aquel más cercano al blanco.*

necesario tener en cuenta que un nodo no puede comunicarse con toda la red sino con aquellos nodos situados dentro de su radio de alcance R_F , R_{rf} , y que denominaremos vecinos. Además, es fundamental mantener la premisa de ahorro energético por lo que se han definido cuatro estados en los que puede estar un nodo de la red:

- **Sleeping.** Estado de ahorro energético en el que el nodo no capta medidas ni establece comunicaciones con sus vecinos. Los sensores pasarán al estado *scanning* de forma aleatoria.
- **Scanning.** Estado de captación de medidas. En este estado el sensor del nodo comienza a tomar medidas y a procesarlas para el cálculo de energía. Los sensores *scanning* pasarán al estado *sensing* cuando la energía medida supere un determinado umbral. Dicho umbral se corresponde con el valor de energía que se mediría si el blanco estuviera a una distancia dada por el radio de cobertura acústica, R_{ca} .

- **Sensing.** Estado de blanco cercano. Cuando un nodo pasa al estado *sensing* significa que el blanco está dentro de su zona de cobertura acústica. El nodo pasará al estado *leading* si es elegido líder de entre todos sus vecinos.
- **Leading.** Estado de líder. Cuando un nodo está en estado *leading* significa que, de entre todos sus vecinos, es el que ha captado un valor mayor de energía acústica y, por tanto, es elegido líder. El líder pondrá en modo *scanning* a todos sus vecinos y será quien lleve a cabo el algoritmo de estima de la trayectoria del blanco.




Figura 3.6: *Ejemplo de los diferentes estados por los que va pasando un nodo.*

Como podemos observar en la figura 3.6, los nodos se encuentran dormidos (estado *sleeping*) hasta que de forma aleatoria comienzan a tomar medidas (estado *scanning*) (a). Cuando un nodo *scanning* detecta al blanco pasará a modo *sensing* (b). Normalmente, cuando un nodo comenzó en estado *scanning* de forma aleatoria y pasó a *sensing*, será el único de su vecindad en dicho estado, por tanto,

se convertirá de forma inmediata en líder y pondrá a escanear a sus vecinos (c). Los nodos vecinos que detecten al blanco pasarán, también, a modo *sensing* (d). Finalmente, un nodo *sensing* comparará su medida de energía con la de sus vecinos para saber si es el más próximo al blanco o, por el contrario, otro nodo debe convertirse en el líder (estado *leading*) (e). De esta manera se irá repitiendo todo el proceso a lo largo del tiempo (f).

El proceso de cambio de líder se denomina *handover*. En dicho proceso se produce el intercambio de toda la información necesaria para el procesamiento del algoritmo, entre el antiguo y el nuevo líder.




Figura 3.7: El líder va cambiando según la trayectoria seguida por el blanco.

No es deseable que haya un gran número de *handovers* a lo largo de la ejecución del algoritmo ya que supone el intercambio de gran cantidad de información con su consecuente gasto energético. Por ello será necesario establecer unos buenos parámetros que establezcan cuando realizar dicho proceso.

3.3. Descripción de la solución propia

Nuestro objetivo consiste en ir estimando, a lo largo del tiempo, la trayectoria que sigue un blanco que se introduce en un terreno monitoreado por la red de sensores descrita en la sección anterior. Con el fin de alcanzar tal objetivo se han combinado y adaptado algunos de los algoritmos de localización y seguimiento ya explicados, de tal manera que dicha tarea se realice de la forma más sencilla y con el menor gasto de recursos posible.

Como se ha venido explicando a lo largo del trabajo, se ha utilizado el modelo de espacio de estados para resolver el problema, estando compuesto el vector de estado en el instante t , \underline{x}_t , por la posición,

\underline{r}_t , y la velocidad, $\dot{\underline{r}}_t$, del blanco en dicho instante:

$$\underline{x}_t = \begin{bmatrix} \underline{r}_t \\ \dot{\underline{r}}_t \end{bmatrix} \quad (3.10)$$

Siendo los modelos del sistema y de movimiento representados por las ecuaciones (3.2) y (3.7), respectivamente.

El nodo líder será el encargado de ejecutar nuestra solución, logrando estimar el vector de estado a lo largo del tiempo. Un cambio de líder supondrá el intercambio de la información sobre dicha estimación entre los nodos involucrados. Este hecho implica que para la ejecución del algoritmo, a parte de la medida realizada por el sensor, se dispone de la estima del vector de estado en el instante anterior. Por tanto, parece que un algoritmo de seguimiento secuencial puede ser el más adecuado para realizar nuestra tarea.

Sin embargo, dichos algoritmos de seguimiento secuencial requieren, para su buen funcionamiento, una buena inicialización del vector de estado. Además, una mala estimación de dicho vector en un instante, provocado por diversas causas (ruido, fallo del nodo, etc.), puede provocar, que a partir de ese momento, el resto de estimas sean también erróneas. Es por ello que utilizamos un algoritmo de localización, que estima la posición utilizando únicamente las medidas, tanto para la inicialización del vector de estado, como para la corrección de la estima de dicho vector en determinados instantes de tiempo.

Por tanto, podremos separar nuestra solución en dos fases: fase de inicialización y fase de funcionamiento. En la fase de funcionamiento podremos distinguir entre el periodo de seguimiento y el periodo de localización.

- **Periodo de Seguimiento, T_s .** Tiempo que transcurre entre dos instantes consecutivos de ejecución del algoritmo de seguimiento.
- **Periodo de Localización, T_l .** Tiempo que transcurre entre dos instantes consecutivos de ejecución del algoritmo de localización.

El periodo de localización será bastante mayor que el de seguimiento, tal como indica la figura 3.8, ya que simplemente se ejecutan para corregir un posible error que vaya acumulándose durante el seguimiento debido al carácter secuencial de éste.

Finalmente, únicamente falta determinar cuales de los algoritmos explicados en el capítulo anterior, utilizaremos en nuestra solución. En cuanto a la localización, el elegido será el algoritmo basado en la




Figura 3.8: Es importante distinguir entre los instantes de localización y los instantes de seguimiento.

energía acústica ya que el diseño de la red y las características tanto de los nodos como del blanco, se adaptan perfectamente a su funcionamiento.

En cuanto al seguimiento, el carácter no lineal del modelo de medida limita nuestra elección. Por un lado, podremos utilizar el Filtro de Partículas de tal manera que no tengamos que realizar ninguna suposición estadística. Por otro lado, también podrán ser elegidos tanto el **EKF** como el **UKF** ya que asumen la no linealidad del modelo. Para no limitar nuestra solución hemos implementado el seguimiento con los tres algoritmos mencionado, siendo el resultado válido en los tres casos como veremos en el capítulo siguiente de simulaciones y resultados. En la elección de uno u otro habrá que sopesar las ventajas e inconvenientes que presentan cada uno de ellos.

A continuación pasamos a detallar cada una de las fases de las que consta nuestra solución.

3.3.1. Fase de inicialización

Como el propio nombre indica, el objetivo de esta fase será la inicialización del vector de estado, sabiendo que dicho vector consta de la posición y de la velocidad del blanco. Para dicha inicialización, el nodo líder únicamente puede disponer de su medida de energía y de la de sus vecinos. Por tanto, será necesario ejecutar el algoritmo de localización para cumplir el objetivo.

Sin embargo, el algoritmo basado en la energía acústica (algoritmo elegido para la localización) únicamente es capaz de estimar la posición instantánea del blanco. Por tanto, será necesario ejecutar dos veces consecutivas dicho algoritmo para poder estimar la velocidad y, así, disponer de una estima completa del vector de estado. Al tiempo transcurrido entre dichos instantes consecutivos de ejecución

del algoritmo se denominará “periodo de inicialización”, T_i .

Por tanto el proceso de inicialización será de la siguiente manera:

1. Instante $t = 0$ ¹

Ejecución AEA \Rightarrow Resultado: \underline{r}_0

2. Instante $t = T_i$

Ejecución AEA \Rightarrow Resultado: \underline{r}_{T_i} .

Inicialización de la velocidad:

$$\dot{\underline{r}}_{T_i} = \frac{\underline{r}_{T_i} - \underline{r}_0}{T_i} \quad (3.11)$$

Una vez finalizada la fase de inicialización, podrá comenzar la fase de funcionamiento con los algoritmos de seguimiento secuencial que parten con el conocimiento del vector de estado de inicialización:

$$\underline{x}_{T_i} = \begin{bmatrix} \underline{r}_{T_i} \\ \dot{\underline{r}}_{T_i} \end{bmatrix} \quad (3.12)$$

3.3.2. Fase de funcionamiento

Tras la fase de inicialización, comienza la fase de funcionamiento. Dicha fase finalizará en el momento en el que el blanco abandone el terreno monitorizado.

Como hemos visto, de la fase de inicialización obtenemos el vector de estado que nos permite inicializar de forma adecuada los algoritmos de seguimiento secuenciales. Tales algoritmos realizan una buena estimación del estado ya que disponen tanto de la información del estado en el instante anterior, como de las medidas realizadas por el líder y sus vecinos. Sin embargo, la propia naturaleza secuencial implica que un error en la estima del estado cometido en un instante sea propagado a lo largo del tiempo. Es por ello que cada cierto tiempo (periodo de localización, T_l) es ejecutado el algoritmo de localización basado en las energías que realiza una estimación del estado basándose únicamente en las medidas, siendo dicha estimación independiente del estado en el instante anterior.

Cabe destacar que en todo el proceso el nodo líder utilizará tanto la medida realizada por su sensor como la de sus vecinos. Por tanto, el vector de medida, \underline{z}_t , estará formado por todas ellas.

$$\underline{z}_t = \left\{ \underline{z}_t^{(k)} \right\}_{k=1}^K \quad (3.13)$$

¹El instante $t = 0$ corresponde al instante en el comienza a ejecutarse nuestro algoritmo de estima de la trayectoria en el primer nodo elegido como líder

siendo $\underline{z}_t^{(1)}$ la medida realizada por el líder en el instante t y $\left\{\underline{z}_t^{(k)}\right\}_{k=2}^K$ la medida realizada por cada uno de sus vecinos en dicho instante.

A continuación se detallarán los algoritmos utilizados en cada de las etapas de las que consta esta fase de funcionamiento: localización y seguimiento.

Localización

Como hemos explicado con anterioridad, la localización pretende estimar la posición del sistema teniendo en cuenta únicamente las medidas realizadas por el líder y sus vecinos. De esta manera se tiene un resultado independiente de las estimaciones obtenidas en instantes anteriores, evitándose, así, propagaciones del error en la posición a lo largo del tiempo.

Por tanto, la localización sirve para obtener un vector de estado con el que inicializar, en determinados instantes de tiempo, los algoritmos secuenciales de seguimiento, asegurándonos que un error cometido en la estimación (debido a una mala medida, a un error del algoritmo, etc.) no va a ser propagado.

Debido a la naturaleza tanto de los sensores como del blanco, el algoritmo de localización elegido ha sido aquel basado en la energía acústica que explicamos en el capítulo anterior. En dicho capítulo fue detallado su funcionamiento extensamente, así que en esta sección sólo vamos comentar las pequeñas adaptaciones.

En nuestra solución el líder, nodo que ejecutará el algoritmo, sólo conoce su medida de energía y la de sus vecinos. Por otra parte, sabemos que las hiperesferas se forman con la energía medida por pares de sensores. Por tanto, se generarán las hiperesferas con la relaciones entre las energías de pares de sensores que componen la vecindad del líder, es decir, él mismo y sus vecinos.

Adicionalmente, el algoritmo lo que hace es obtener la posición que minimiza la función de coste, (2.24). Dicha minimización se realiza de una manera secuencial. En nuestra solución, para que la convergencia de la minimización sea rápida se comienza por la estimación de la posición realizada en el instante anterior.

Por otra parte, sabemos que el algoritmo de localización basado en las energías únicamente nos proporciona el valor de la posición, \underline{r}_t . Por tanto, para generar un vector de estado, \underline{x}_t válido para la inicialización de los algoritmos de seguimiento secuenciales, será necesario determinar, también, la velocidad del blanco, $\dot{\underline{r}}_t$. Para ello, se utiliza la estima de la posición realizada en el instante anterior,

según indica la siguiente ecuación:

$$\dot{\underline{r}}_t = \frac{\underline{r}_t - \underline{r}_{t-1}}{T} \quad (3.14)$$

siendo T el intervalo de tiempo transcurrido entre dos instantes de estima de la posición consecutivos, t y $t - 1$.

Tras esta fase de localización tendremos un vector de estado, \underline{x}_t , válido para inicializar, de nuevo, los algoritmos secuenciales que actuarán en la siguiente fase de seguimiento.

Seguimiento

Una vez obtenido un vector de estado de inicialización (tras la etapa de inicialización o tras una fase de localización) puede empezar a ejecutarse cualquiera de los algoritmos de seguimiento secuencial que vimos en el capítulo anterior, a excepción del Kalman Filter (**KF**). Dicho algoritmo no puede ser utilizado ya que presupone una naturaleza lineal de los modelos del sistema y de medida. Sin embargo, como vimos en la descripción de la red de sensores, el modelo de medida es no lineal, por tanto, únicamente podremos utilizar el Filtro de Partículas (**FP**), el Extended Kalman Filter (**EKF**) o el Unscented Kalman Filter (**UKF**), que no parten de la premisa de linealidad. Dichos algoritmos son adaptados a nuestra solución de la siguiente manera:

FP

- **Paso 1.** Recepción de las partículas del instante anterior: $\left\{ \underline{x}_{t-1}^{(i)}, 1/N \right\}_{i=1}^N$ Si en el instante anterior fue ejecutado el algoritmo de localización en lugar del de seguimiento, tendremos el conocimiento del vector de estado, \underline{x}_{t-1} , en lugar de de las partículas. Por tanto, será necesario inicializar éstas, de forma aleatoria, alrededor de dicho vector de estado.
- **Paso 2.** Predicción de cada una de las partículas según el modelo del sistema (3.2).

$$\underline{x}_t^{(i)} = \underline{F} \underline{x}_{t-1}^{(i)} + \underline{\Gamma} v_t \quad (3.15)$$

Nótese que no se conoce el valor del ruido del proceso v_t , sin embargo, la experiencia nos dará su distribución y éste podrá ser generado de forma aleatoria.

- **Paso 3.** Obtención de los pesos de las partículas partiendo del conocimiento de las medidas de energía realizada por el líder y por sus vecinos, z_t y del modelo de medida. Es el denominado "Muestreo secuencial enfatizado".

$$w_t^{(i)} \propto \frac{1}{N} \left[p(z_t | \underline{x}_t^{(i)}) p(\underline{x}_t^{(i)} | \underline{x}_{t-1}^{(i)}) \right] \quad (3.16)$$

Estos pesos son normalizados, por tanto, tras este paso se tendrá el conjunto de pesos $\{w_t^{(i)}\}_{i=1}^N$ tal que $\sum_i^N w_t^i = 1$

- **Paso 4.** Realización del remuestreo con el objeto de eliminar aquellas partículas cuyo peso sea tan pequeño, que degradan la estima del estado. Para saber si el proceso de remuestreo es necesario, se calcula el tamaño efectivo de la muestra, N_{ef} , que nos da una idea del número de partículas que contribuyen significativamente a la estimación.

$$N_{ef} = \frac{1}{\sum_{i=1}^N \left(w_t^{(i)}\right)^2} \quad (3.17)$$

Si $N_{ef} \leq N_{umbral}^2$, se lleva el remuestreo. Tras este paso, se tendrá un nuevo conjunto de partículas $\{\underline{x}_t^{(i)*}, 1/N\}_{i=1}^N$ con pesos uniformes. El nuevo conjunto de muestras aleatorias $\{\underline{x}_t^{(i)*}\}_{i=1}^N$ se genera remuestreando y reemplazando el conjunto de muestras $\{\underline{x}_t^{(i)}\}_{i=1}^N$, de tal forma que la probabilidad de elegir a una partícula está directamente relacionada con el valor de su peso, es decir, $p(\underline{x}_t^{(i)*} | \underline{x}_t^{(j)}) \propto w_t^{(j)}$.

- **Paso 5.** Estimación del estado, \underline{x}_t , a partir de las partículas obtenidas en el paso anterior.

$$\underline{x}_t = \sum_{i=1}^N \frac{1}{N} \underline{x}_t^{(i)*} \quad (3.18)$$

EKF

- **Paso 1.** Recepción de la estimación del estado en el instante anterior, $\hat{\underline{x}}_{t-1}$, junto con su covarianza, $\underline{P}_{\underline{x}_{t-1}}$. Si en el instante anterior, fue ejecutado un algoritmo de localización, dicha covarianza valdrá 1.

²Donde N_{umbral} es un parámetro experimental a partir del cual se considera que la degeneración de la población de partículas requiere la participación de una fase de remuestreo.

- **Paso 2.** Predicción del estado en el instante actual según el modelo del sistema (3.2).

$$\hat{\underline{x}}_t^- = \underline{F} \hat{\underline{x}}_{t-1} + \underline{\Gamma} v_t \quad (3.19)$$

Nótese que no se conoce el valor del ruido del proceso v_t , sin embargo, la experiencia nos dará su distribución y éste podrá ser generado de forma aleatoria.

- **Paso 3.** Linealización local de las funciones no lineales correspondientes a los modelos del sistema y de medida. En el caso del modelo del sistema existe una relación lineal entre el estado de dos instantes consecutivos (como vemos en la ecuación (3.19)), por tanto, no será necesaria realizar dicha linealización. Sin embargo, en el caso del modelo de medida si es necesaria realizar la linealización. Para ello se aplica a la función h , dada por la ecuación (3.7), la matriz Jacobiana de derivadas parciales:

$$\hat{\underline{H}}_{[i,j]} = \frac{\partial h_{[i]}}{\partial x_{[j]}}(\hat{\underline{x}}_t^-) \quad (3.20)$$

- **Paso 4.** Cálculo de la covarianza de la predicción del estado $\underline{P}_{x_t^-}$.

$$\underline{P}_{x_t^-} = \underline{F} \underline{P}_{x_{t-1}} \underline{F}^T + \underline{Q} \quad (3.21)$$

- **Paso 5.** Predicción de la medida, $\hat{\underline{z}}_t$, y de su covarianza, \underline{P}_{z_t}

$$\hat{\underline{z}}_t = h(\hat{\underline{x}}_t^-) \quad (3.22)$$

$$\underline{P}_{z_t} = \hat{\underline{H}} \underline{P}_{x_t^-} \hat{\underline{H}}^T + \underline{R} \quad (3.23)$$

- **Paso 6.** Cálculo de la covarianza de la predicción del estado dada la nueva medida, de la ganancia de Kalman y de la covarianza del estado actual.

La covarianza de la predicción del estado dada la nueva medida:

$$\underline{P}_{x_t^-|z_t} = \underline{P}_{x_t^-} \hat{\underline{H}}^T \quad (3.24)$$

La ganancia de Kalman:

$$\underline{K}_t = \frac{\underline{P}_{x_t^-|z_t}}{\underline{P}_{z_t}} = \underline{P}_{x_t^-} \hat{\underline{H}}^T (\hat{\underline{H}} \underline{P}_{x_t^-} \hat{\underline{H}}^T + \underline{R})^{-1} \quad (3.25)$$

La covarianza del estado actual:

$$\underline{P}_{x_t} = \underline{P}_{x_t^-} - \underline{K}_t \underline{P}_{z_t} \underline{K}_t^T = (I - \underline{K}_t \hat{\underline{H}}) \underline{P}_{x_t^-} \quad (3.26)$$

donde $f(\cdot)$ y $h(\cdot)$ son las funciones no lineales, y $\hat{\underline{F}}$ y $\hat{\underline{H}}$ son las linealizaciones locales de tales funciones.

- **Paso 7.** Actualización de la estimación del estado con la nueva medida.

$$\hat{\underline{x}}_t = \hat{\underline{x}}_t^- + \underline{K}_t (\underline{z}_t - \hat{\underline{z}}_t) \quad (3.27)$$

UKF

- **Paso 1.** Recepción de la estimación del estado en el instante anterior, $\hat{\underline{x}}_{t-1}$, junto con su covarianza, $\underline{P}_{x_{t-1}}$. Si en el instante anterior, fue ejecutado un algoritmo de localización, dicha covarianza valdrá 1.
- **Paso 2.** Cálculo de los puntos sigma que representan la densidad de probabilidad a posteriori del instante anterior.

$$\begin{aligned} \chi_{t-1}^{(0)} &= \hat{\underline{x}}_{t-1} \\ \chi_{t-1}^{(i)} &= \hat{\underline{x}}_{t-1} + \left(\sqrt{(n+\lambda) \underline{P}_{x_{t-1}}} \right)_i \quad i = 1, \dots, n \\ \chi_{t-1}^{(i)} &= \hat{\underline{x}}_{t-1} - \left(\sqrt{(n+\lambda) \underline{P}_{x_{t-1}}} \right)_i \quad i = n+1, \dots, 2n \\ W_{t-1}^{m(0)} &= \frac{\lambda}{n+\lambda} \\ W_{t-1}^{p(0)} &= \frac{\lambda}{n+\lambda} + (1 - \alpha^2 + \beta) \\ W_{t-1}^{m(i)} &= W_{t-1}^{p(i)} = \frac{1}{2(n+\lambda)} \quad i = 1, \dots, 2n \end{aligned} \quad (3.28)$$

donde $\lambda = \alpha^2(L + \kappa) - L$ es el parámetro escalado; α determina la propagación de los puntos sigma y normalmente es un valor pequeño, por ejemplo, 10^{-3} ; κ es el parámetro de escalado secundario, cuyo valor suele ser nulo; y β se utiliza para incorporar el conocimiento anterior de la distribución, y su valor óptimo para una distribución gaussiana es 2.

- **Paso 3.** Predicción de los puntos sigma que representan la densidad de probabilidad a posteriori del estado, en el instante actual.

$$\chi_t^{(i)} = f(\chi_{t-1}^{(i)}, v_{t-1}) \quad (3.29)$$

- **Paso 4.** Predicción del estado en instante actual y de su covarianza.

$$\hat{\underline{x}}_t^- = \sum_{i=0}^{2n} W_{t-1}^{m(i)} \chi_t^{(i)} \quad (3.30)$$

$$\underline{P}_{x_t^-} = \sum_{i=0}^{2n} W_{t-1}^{p(i)} (\chi_t^{(i)} - \hat{\underline{x}}_t^-)(\chi_t^{(i)} - \hat{\underline{x}}_t^-)^T + \underline{Q} \quad (3.31)$$

- **Paso 4.** Predicción de los puntos sigma que representa la densidad de probabilidad de la medida, en el instante actual.

$$Z_t^{(i)} = h(\chi_t^{(i)}) \quad (3.32)$$

- **Paso 5.** Predicción de la medida y de su covarianza.

$$\hat{z}_t = \sum_{i=0}^{2n} W_{t-1}^{m(i)} Z_t^{(i)} \quad (3.33)$$

$$\underline{\underline{P}}_{z_t} = \sum_{i=0}^{2n} W_{t-1}^{p(i)} (Z_t^{(i)} - \hat{z}_t)(Z_t^{(i)} - \hat{z}_t)^T + \underline{\underline{R}} \quad (3.34)$$

- **Paso 6.** Cálculo de la covarianza de la predicción del estado dada la nueva medida, de la ganancia de Kalman y de la covarianza del estado actual.

Cálculo covarianza de la predicción del estado dada la nueva medida:

$$\underline{\underline{P}}_{x_t^-|z_t} = \sum_{i=0}^{2n} W_{t-1}^{p(i)} (\chi_t^{(i)} - \hat{x}_t^-)(Z_t^{(i)} - \hat{z}_t)^T \quad (3.35)$$

Cálculo de la ganancia de Kalman:

$$\underline{\underline{K}}_t = \frac{\underline{\underline{P}}_{x_t^-|z_t}}{\underline{\underline{P}}_{z_t}} \quad (3.36)$$

Cálculo de la covarianza del estado actual:

$$\underline{\underline{P}}_{x_t} = \underline{\underline{P}}_{x_t^-} - \underline{\underline{K}}_t \underline{\underline{P}}_{z_t} \underline{\underline{K}}_t^T \quad (3.37)$$

- **Paso 7.** Actualización de la estimación del estado con la nueva medida.

$$\hat{x}_t = \hat{x}_t^- + \underline{\underline{K}}_t (z_t - \hat{z}_t) \quad (3.38)$$

3.4. Resumen

A lo largo del capítulo, hemos planteado nuestra solución al problema de estima de la trayectoria de un blanco. Su velocidad variará de manera constante en cada intervalo de muestreo de la señal acústica emitida por dicho blanco.

Para alcanzar nuestro objetivo, se ha optado por un diseño en cuadrícula de la red, formada por nodos acústicos. Dicho diseño en cuadrícula facilita el funcionamiento de la red basado en líder, siendo

tal nodo aquel que ejecutará el algoritmo oportuno. Para ello, dicho nodo utiliza, a parte de sus medidas, aquellas realizadas por sus vecinos, mejorando de esta manera la precisión de la estimación.

Finalmente, hemos visto como los algoritmos secuenciales de seguimiento que no suponen un carácter lineal del modelo (**FP**, **EKF** y **UKF**) son perfectamente válidos para alcanzar el objetivo, ya que con el conocimiento de la estima en el instante anterior y las medidas, realizan una buena estimación del estado. Sin embargo, dichos algoritmos necesitan de la inicialización del estado para funcionar. La inicialización es obtenida mediante el algoritmo de localización basado en las energías. Este algoritmo es ejecutado, adicionalmente, en determinados instantes de tiempo con el objetivo de corregir posibles errores acumulados a lo largo del tiempo por los algoritmos secuenciales. Los algoritmos de localización no acumulan errores ya que estiman el estado con el único conocimiento de las medidas.

A continuación veremos la simulaciones y resultados obtenidos por nuestra solución.

SIMULACIONES Y RESULTADOS

A continuación se muestran los resultados de una serie de simulaciones de la solución propuesta para la estimación de la trayectoria de un blanco.

Cabe destacar lo complicado que supone la simulación del sistema debido a la gran cantidad de parámetros de los que depende y de la interrelación entre ellos. La idea que se plantea es fijar un escenario, relativamente sencillo, y mostrar el correcto funcionamiento de la solución. Dicha solución será implementada con tres algoritmos de seguimiento diferentes: **FP**, **EKF** y **UKF**, haciendo una pequeña comparación del error cometido por cada uno de ellos. Además, se comprobará el comportamiento del error con respecto al ruido.

En nuestro escenario, el blanco seguirá un movimiento uniformemente acelerado, en el que la velocidad entre intervalos de muestreo puede ser considerada constante. En las simulaciones consideraremos que la velocidad máxima será 15 m/s (velocidad típica para vehículos *off road*). En cuanto a las trayectorias seguidas por el blanco, se han considerado dos diferentes: rectilínea de velocidad constante y variable con aceleración y velocidad aleatorias.

En las simulaciones hemos considerado que los blancos a localizar emiten una onda acústica de amplitud aleatoria uniformemente distribuida en el intervalo $[a_{lo}, a_{hi}]$. Se considera que el radio de cobertura acústica, R_{ca} , permite que todo punto del terreno monitorizado esté cubierto por la cobertura de al menos 4 nodos (ver Figura 3.4).

Por otro lado, se considerará que el radio de alcance **RF**, R_{rf} , es tal que un nodo es capaz de comunicarse con los 8 nodos más cercanos.

La red está formada por N sensores equiespaciados distribuidos a lo largo de una cuadrícula. Con esta configuración y considerando un R_{ca} de 71 metros, es posible cubrir una zona de $400 \times 400 m^2$ con

64 sensores.

En primer lugar, se mostrarán los resultado para dos trayectorias diferentes rectilíneas (una vertical y otra transversal) en las que el blanco lleva una velocidad constante igual a 15 m/s . En segundo lugar, observaremos una simulación en la que el blanco seguirá un movimiento uniformemente acelerado. La velocidad entre intervalos de muestreo podrá ser considerada constante, pero de un intervalo a otro varía de forma aleatoria, teniendo un valor medio de 15 m/s . Esta simulación dará lugar a una trayectoria totalmente aleatoria. Por último, tendremos una visión del comportamiento de la solución frente a diferentes valores de ruido.

La energía de ruido máxima en el sistema es fijada al valor que mediría un nodo si el blanco estuviera emitiendo su amplitud acústica mínima, a_{lo} , y estuviera situado al límite del R_{ca} de dicho nodo. Es decir, estamos fijando el máximo del ruido en el peor caso posible y, por tanto, la relación señal a ruido (*Signal to Noise Ratio*, **SNR**) mínima. En cualquier otro caso (menos ruido, blanco más cercano al nodo o mayor energía emitida por el mismo), la SNR captada por el nodo sería mayor.

$$SNR_{minima}[dB] = S_{minima}[dB] - N_{maxima}[dB] \quad (4.1)$$

$$s_{minima} = \left(\frac{a_{lo}}{R_{ca}} \right)^2 \quad (4.2)$$

siendo s_{minima} la energía mínima que captaría un nodo si el blanco estuviera situado al borde su zona de cobertura ($distancia = R_{ca}$) y este estuviera emitiendo su mínima energía acústica (a_{lo}). S_{minima} es la anterior energía en dBs . N_{maxima} es la energía máxima de ruido fijada en el sistema (en dBs).

A continuación, se muestran las diferentes simulaciones realizadas.

4.1. Trayectoria Vertical

En esta simulación el blanco sigue una trayectoria rectilínea en dirección vertical, con velocidad constante igual a 15 m/s . La **SNR** mínima se fija a $10dB$.

En la figura 4.1, observamos la trayectoria seguida por el blanco y la trayectoria estimada por nuestra solución utilizando cada uno de los algoritmos de seguimiento elegidos (**FP**, **EKF**, **UKF**). Cabe destacar como la mayor diferencia entre la trayectoria seguida y la trayectoria estimada se produce en los instantes de mayor **SNR**, es decir, cuando la distancia del blanco al nodo más cercano es máxima.

La figura 4.2 muestra el error cometido a lo largo de la trayectoria por nuestra solución empleando los tres algoritmos de seguimiento.




Figura 4.1: *Trayectoria vertical seguida por el blanco y estimada por los diferentes algoritmos.*




Figura 4.2: *Error cometido por cada uno de los algoritmos para una trayectoria vertical.*

La Tabla 4.1 muestra el error medio, medido en metros, cometido por nuestra solución, empleando cada uno de los algoritmos de seguimiento propuestos.

Tabla 4.1:

FP	EKF	UKF
0,30552	0,50248	0,11848

Vemos como el error medio, en los tres casos, se encuentra en unos valores más que aceptables. Sin embargo, más que el error medio, nos interesa conocer las funciones de distribución y de densidad de probabilidad del error para cada algoritmo. Éstas las podemos observar en la figura 4.3

La función de distribución representa la probabilidad de que el error esté por debajo de un determinado umbral, ϵ , mientras que la función de densidad representa la probabilidad del error. Por tanto, en tales gráficas podemos observar tanto el error máximo, como el error más probable.

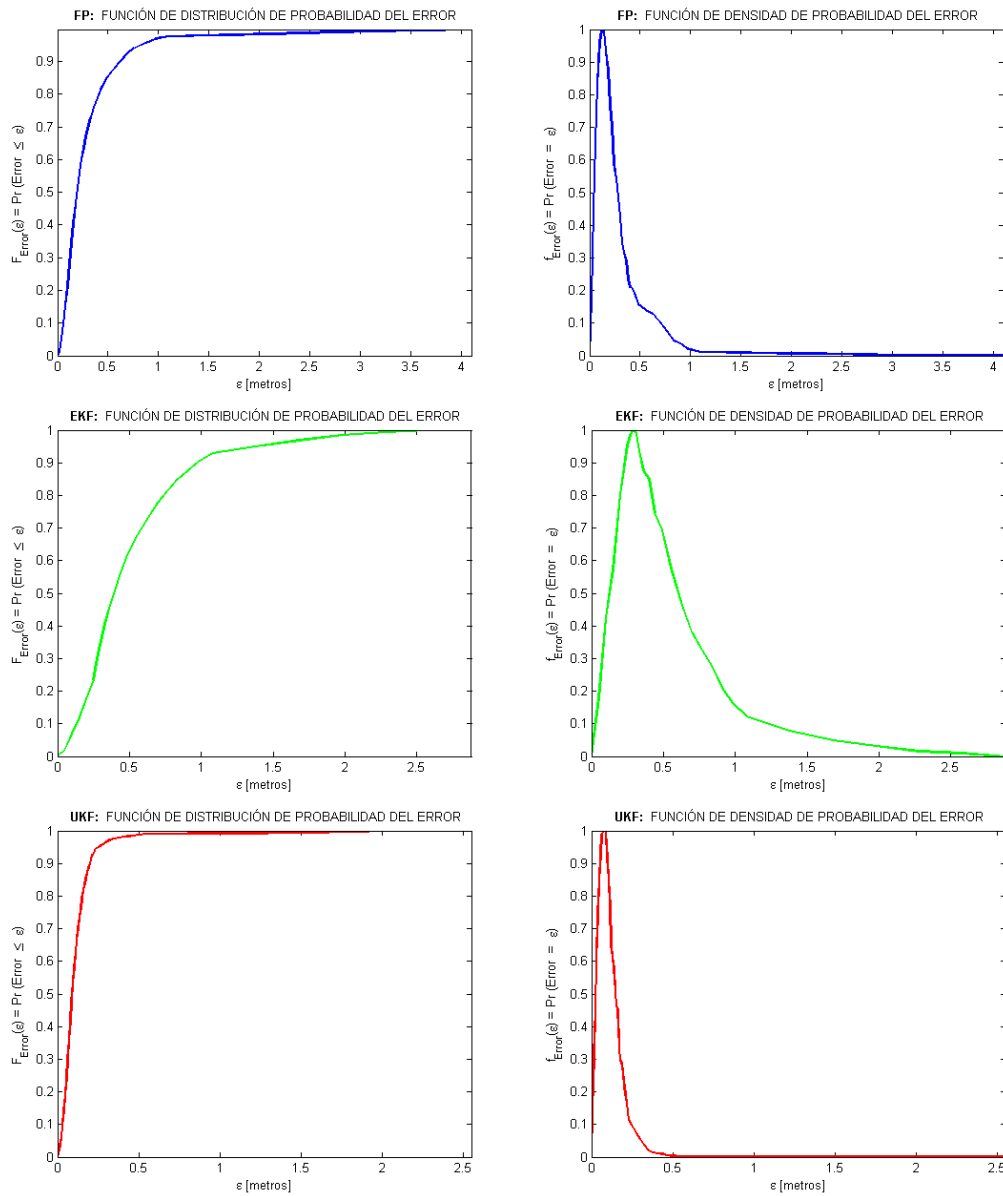


Figura 4.3: Función de distribución y de densidad del error para una trayectoria vertical.

4.2. Trayectoria Transversal

En esta simulación el blanco sigue una trayectoria rectilínea en dirección transversal, con velocidad constante igual a 15 m/s . La **SNR** mínima se fija a 10dB .




Figura 4.4: *Trayectoria transversal seguida por el blanco y estimada por los diferentes algoritmos.*

En la figura 4.4, observamos la trayectoria seguida por el blanco y la trayectoria estimada por nuestra solución utilizando cada uno de los algoritmos de seguimiento elegidos (**FP**, **EKF**, **UKF**). Al igual que ocurría con la trayectoria vertical la mayor diferencia entre la trayectoria seguida y la trayectoria estimada se produce en los instantes de mayor **SNR**, es decir, cuando la distancia del blanco al nodo más cercano es máxima. La Tabla 4.2 muestra el error medio, medido en metros, cometido




Figura 4.5: *Error cometido por cada uno de los algoritmos para una trayectoria transversal.*

Tabla 4.2:

FP	EKF	UKF
0,4333	0,57233	0,12491

por nuestra solución, empleando cada uno de los algoritmos de seguimiento propuestos. Vemos como el error medio, en los tres casos, es similar al calculado en la trayectoria vertical, como era de esperar. En este caso, también nos interesa conocer las funciones de distribución y de densidad de probabilidad del error para cada algoritmo. Éstas las podemos observar en la figura 4.6.

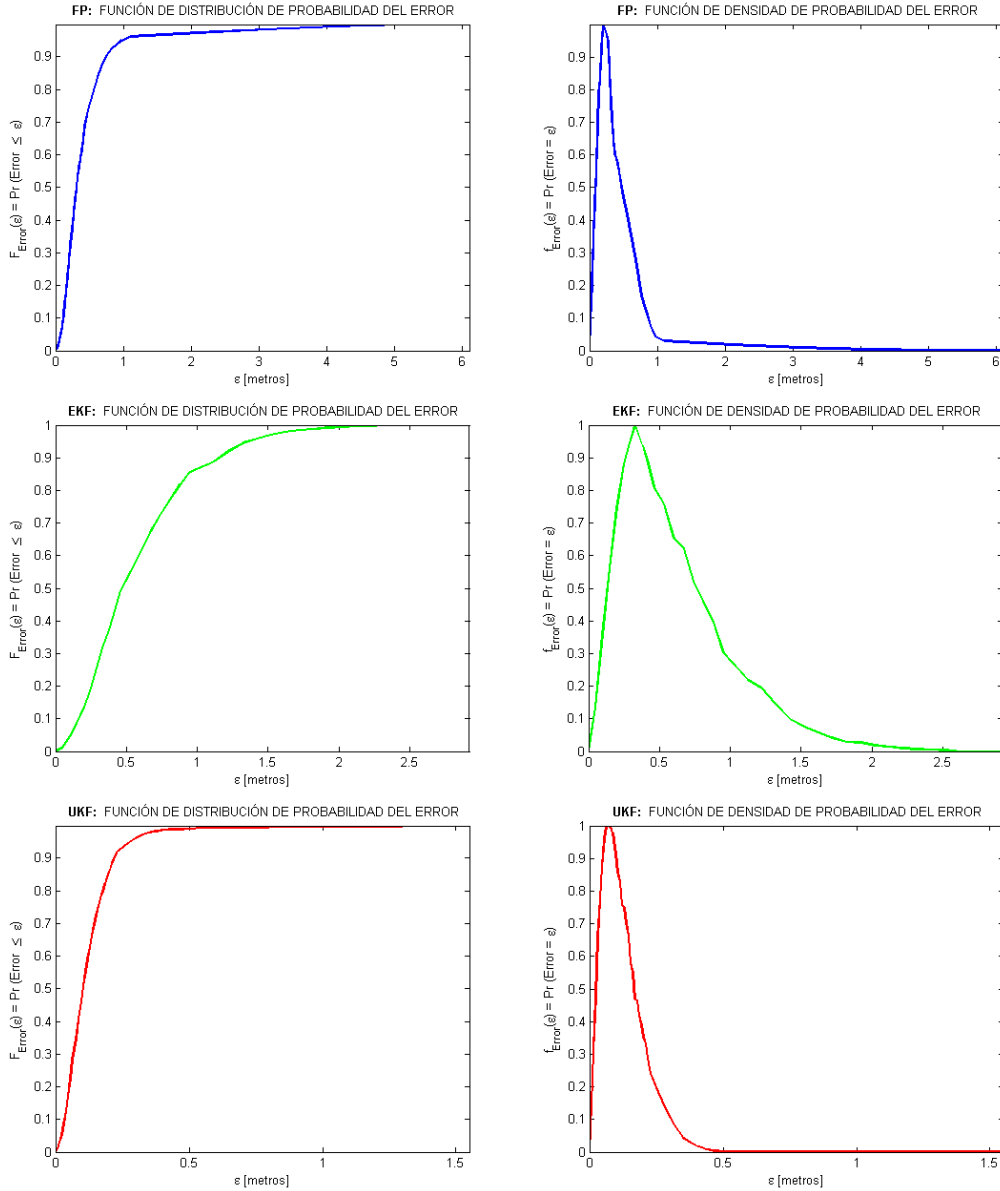


Figura 4.6: *Función de distribución y de densidad del error para una trayectoria transversal.*

Como hemos explicado con anterioridad, la función de distribución representa la probabilidad de que el error esté por debajo de un determinado umbral, ϵ , mientras que la función de densidad representa la probabilidad del error. Por tanto, en tales gráficas podemos observar tanto el error máximo, como el error más probable.

4.3. Trayectoria Aleatoria

En esta simulación el blanco sigue un movimiento uniformemente acelerado. La velocidad entre intervalos de muestreo puede ser considerada constante, pero de un intervalo a otro varía de forma aleatoria, teniendo un valor medio de 15 m/s . La trayectoria, por tanto, puede ser considerada aleatoria. La **SNR** mínima se fija, también, a 10dB .




Figura 4.7: *Trayectoria aleatoria seguida por el blanco y estimada por los diferentes algoritmos.*

En la figura 4.7, observamos la trayectoria seguida por el blanco y la trayectoria estimada por nuestra solución utilizando cada uno de los algoritmos de seguimiento elegidos (**FP**, **EKF**, **UKF**). En la figura 4.8 vemos como, según avanza el blanco, el error va aumentando ligeramente. Esto es debido a que la velocidad de éste va aumentando. Esto se observa de forma más pronunciada en el EKF. Éste es el algoritmo que peor se adapta a cambios más abruptos del estado del blanco debido a la linealización que hace del modelo de medida no lineal.




Figura 4.8: *Error cometido por cada uno de los algoritmos para una trayectoria aleatoria.*

La Tabla 4.3 muestra el error medio, medido en metros, cometido por nuestra solución, empleando cada uno de los algoritmos de seguimiento propuestos.

Tabla 4.3:

FP	EKF	UKF
0,5577	2,1238	0,14321

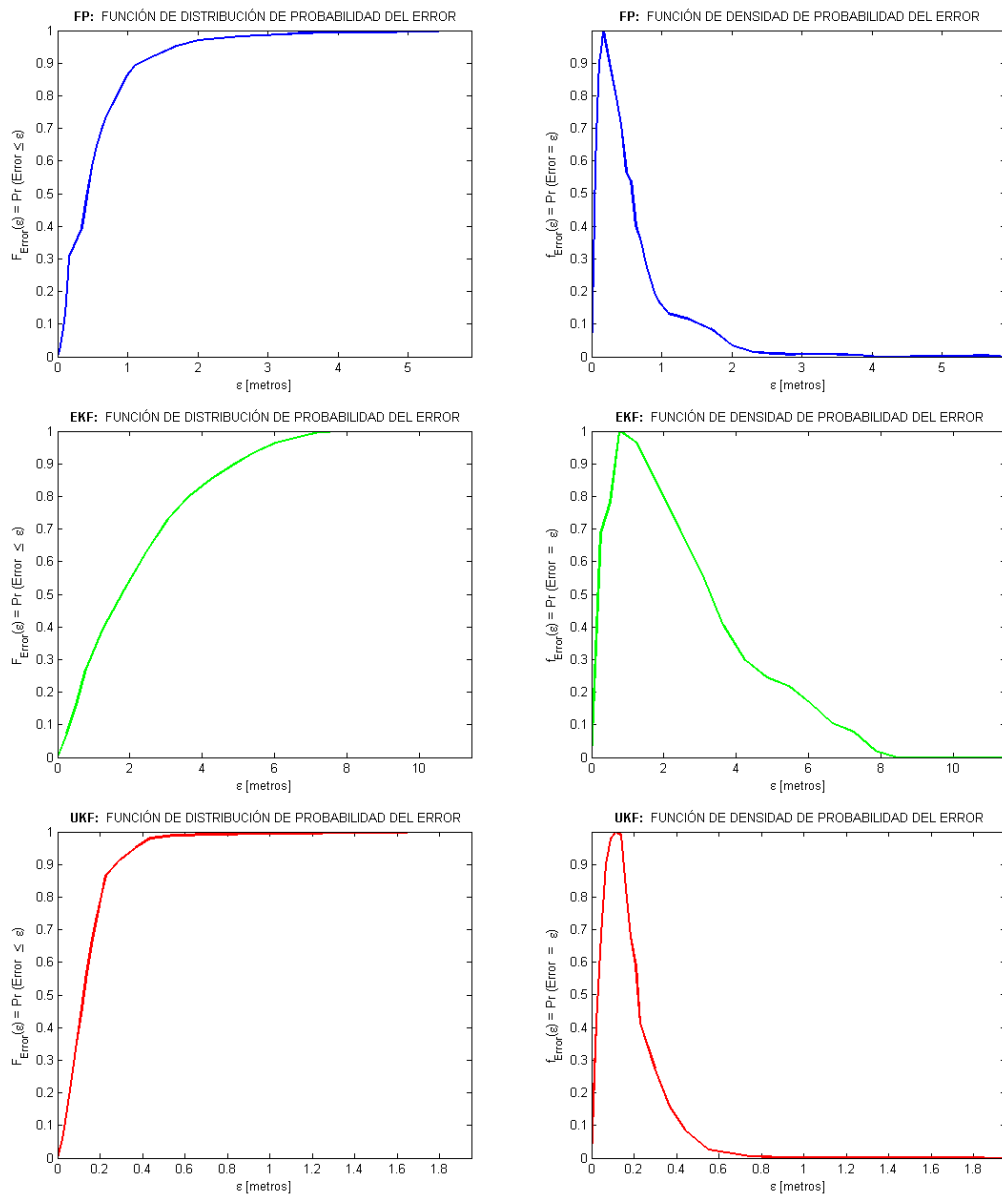


Figura 4.9: Función de distribución y de densidad del error para una trayectoria aleatoria.

A pesar de la aleatoriedad de la trayectoria, el error medio sigue manteniéndose en valores aceptables. En la figura 4.9 podemos observar las funciones de distribución y densidad de probabilidad del error para cada algoritmo.

Como hemos explicado con anterioridad, la función de distribución representa la probabilidad de que el error esté por debajo de un determinado umbral, ϵ , mientras que la función de densidad representa la probabilidad del error. Por tanto, en tales gráficas podemos observar tanto el error máximo, como el error más probable.

4.4. Estudio del Ruido

Por último, realizamos un pequeño estudio del comportamiento de nuestra solución con el ruido. Para ello, fijamos distintos valores de **SNR** mínima y medimos, para cada valor, el error medio que se comete cuando el blanco sigue una trayectoria rectilínea en dirección vertical, con velocidad constante igual a 15 m/s . Dicho estudio se hace empleando cada uno de los algoritmos de seguimiento.




Figura 4.10: *Error medio frente distintos valores de **SNR** mínima.*

La figura 4.10 muestra como, tanto con el **FP**, como con el **EKF** y el **UKF**, el error disminuye al aumentar la **SNR**. Éste era el resultado esperado, un aumento de la relación señal a ruido implica que la medida realizada por los sensores es de mayor calidad produciéndose, por tanto, una estima de la posición más precisa. Parece que el **EKF** es algo más sensible a variaciones de ruido, mientras que la respuesta del **UKF** es algo más estable que la del resto de algoritmos.

4.5. Resumen

Con las simulaciones expuestas en este capítulo, no pretendemos dar unos resultados exhaustivos de errores sino, simplemente, mostrar el correcto funcionamiento de la solución propuesta.

Hemos visto como se estima de forma adecuada la trayectoria del blanco, el cual es capaz de seguir diferentes caminos. En todos los casos el error se mantiene en valores relativamente bajos.

Haciendo una pequeña comparativa de los tres algoritmos de seguimiento que podríamos utilizar en nuestra solución, podemos decir que el **UKF** es el que nos ofrece el menor error y el mejor comportamiento frente al ruido. Por otro lado, el **EKF** es el algoritmo que ofrece los peores resultados. Esto parece ser lo esperado ya que el algoritmo **EKF** sólo es capaz de realizar una aproximación de primer orden del sistema no lineal, mientras que el **UKF** permite obtener una representación de segundo orden.

Por otra parte, también observamos que el **UKF** presenta mejores resultados que el **FP**. Esto es debido a que el ruido generado en las simulaciones es gaussiano y, por tanto, las hipótesis estadísticas tomadas por las variantes del filtro de Kalman son completamente válidas. El **FP**, por el contrario, no asume ninguna distribución estadística de los datos lo que le lleva a tener un error medio algo mayor que el **UKF**.

Capítulo 5

CONCLUSIONES

El objetivo final del proyecto ha sido proponer una serie de estrategias que deriven en una solución válida para el problema de estima de la trayectoria seguida por un blanco, mediante la utilización de redes de sensores.

El desarrollo e implementación de la solución nos ha permitido extraer una serie de conclusiones que se exponen a continuación:

- En la actualidad existe un creciente interés en las tecnologías de localización y seguimiento de blancos en movimiento debido al gran demanda de aplicaciones basadas en ellas. Aunque, tanto en la localización como en el seguimiento, el objetivo es estimar la posición de un blanco, la información que se dispone en cada uno de ellos para alcanzar el objetivo es distinta. La localización estima la posición sin el conocimiento de la posición en instantes anteriores. Únicamente dispone de alguna medida realizada sobre al blanco. Por el contrario, el seguimiento, además de la medida, dispone de la posición en instantes pasados, teniendo, por tanto, un carácter secuencial. Esta diferencia nos hace distinguir entre los algoritmos de localización y los algoritmos de seguimiento.
- Las redes inalámbricas de sensores distribuidas constituyen una buena plataforma para resolver tanto la localización y como el seguimiento. Estas redes están formadas por dispositivos pequeños y baratos, que cuentan con sensores integrados ,y que poseen capacidad de procesado e intercomunicación. Las características de estos nodos hacen que este tipo de redes sean óptimas para la resolución del problema. Sin embargo, también cuentan con otra serie de características, entre las que se encuentra la escasa energía de la que disponen, que se deben tener en cuenta a

la hora de diseñar las diferentes estrategias.

- El modelo de espacio de estados es perfectamente válido para modelar el problema de la localización y el seguimiento. Las propiedades cinemáticas del blanco son introducidas en un vector que representa el estado del sistema/blanco. Además, se cuenta con el modelo del sistema (o modelo de movimiento) que representa la relación entre la posición del blanco en instantes consecutivos, y el modelo de medida, que relaciona la posición actual con la medida realizada sobre dicho blanco.
- Se ha realizado un estudio de diferentes algoritmos de localización y seguimiento ya existentes que, basados en el anterior modelo de espacio de estados, resuelven el problema. En dicho estudio hemos distinguido entre los algoritmos que no asumen ningún tipo de distribución estadística de los datos y que hemos denominado *Tipo I*, y, por otro lado, aquellos que asumen la distribución normal de los mismos, denominándolos *Tipo II*.
- Entre los algoritmos de localización, se han descrito el Filtro de Partículas como ejemplo de algoritmo *Tipo I* y el algoritmo basado en la energía acústica como ejemplo de algoritmo *Tipo II*. Entre los algoritmos de seguimiento, se han descrito el Filtro de Partículas en su versión secuencial como ejemplo de algoritmo *Tipo I* y el filtro de Kalman, junto con alguna de sus variantes no lineales (**EKF** y **UKF**), como ejemplos de algoritmo *Tipo II*. Tanto el diseño de la red, como las características del escenario, nos llevan a la elección de un algoritmo u otro.
- Una de la estrategias propuestas es el despliegue en cuadrícula de la red, de tal manera que la distancia entre los nodos nos permita cubrir de manera adecuada el terreno a monitorizar. Se cubre de manera adecuada ya que cualquier punto del terreno está cubierto por la cobertura del sensor de, al menos, cuatro nodos de la red. Este aspecto es fundamental para nuestra solución ya que para obtener una buena estima de la posición se usa la medida de, al menos, cuatro nodos. Por supuesto, es fundamental limitar el gasto energético debido a las comunicaciones inalámbricas, permitiendo que cualquier nodo únicamente pueda comunicarse con un pequeño conjunto de nodos de la red que se denominan vecinos.
- Otra de las estrategias fundamentales de nuestra solución es el funcionamiento de la red basado en líder. El nodo líder utilizará su medida y la de sus vecinos para estimar el estado del blanco. Dado que el líder será el nodo más cercano al blanco, las medidas utilizadas serán las más adecuadas

para obtener una buena estima. En cualquier instante, cualquier nodo de la red puede llegar a convertirse en líder.

- Un nodo de la red puede llevar integrados uno o varios tipo de sensores. El tipo de sensor nos dice el tipo de medida que se obtiene del blanco. Es decir, nos fija el modelo de medida. Las características de dicho modelo de medida nos llevará a elegir los algoritmos de localización y seguimiento a utilizar. En nuestro caso, hemos optado por sensores acústicos ya que son sencillos y baratos. Gracias a estos sensores acústicos se obtienen medidas de la energía acústica emitida por el blanco, siendo dicha medida inversamente proporcional al cuadrado de la distancia entre el sensor y el blanco. Es decir, existe una relación no lineal entre la medida y la posición.
- Los algoritmos secuenciales de seguimiento que no suponen un carácter lineal del modelo (**FP**, **EKF** y **UKF**) son perfectamente válidos para alcanzar el objetivo, ya que con el conocimiento de la estima en el instante anterior y las medidas, realizan una buena estimación del estado. Sin embargo, dichos algoritmos necesitan de la inicialización del estado para funcionar. La inicialización es obtenida mediante el algoritmo de localización basado en las energías. Este algoritmo es ejecutado, adicionalmente, en determinados instantes de tiempo con el objetivo de corregir posibles errores acumulados a lo largo del tiempo por los algoritmos secuenciales. Los algoritmos de localización no acumulan errores en estimaciones pasadas ya que la estima actual del estado se realiza con el único conocimiento de las medidas.
- Tras la implementación de la solución y la realización de una serie de simulaciones vemos como las estrategias propuestas resuelven el problema de estima de la trayectoria seguida por un blanco en movimiento. La implementación se realiza con tres algoritmos de seguimiento diferentes (**FP**, **EKF**, **UKF**). No se pretende hacer una comparativa exhaustiva de tales algoritmos, sino demostrar que con los tres se obtienen resultados aceptables y que la elección de uno u otro dependerá de a cual se adapten mejor las características del sistema.

5.1. Futuras líneas de investigación

Del presente trabajo se desprenden una serie de posibles futuras líneas de investigación que se exponen a continuación:

- Generalización de la solución propuesta a cualquier tipo de sensor integrado en los nodos e incluso combinación de distintos tipos de medidas para optimizar la estima de la posición.

- De la trayectoria estimada se pueden obtener ciertos parámetros que permiten distinguir entre distintos tipos blanco. Por tanto, es posible la integración de nuestra solución de estima de la trayectoria en un algoritmo de clasificación.
- Establecimiento de soluciones concretas de comunicación entre los nodos.
- Estudio profundo del consumo de recursos (energía, ancho de banda, etc.) para su posible optimización.

APÉNDICES

PRESUPUESTO DEL PROYECTO

A continuación, se justificará el presupuesto global necesario para la realización del Proyecto Fin de Carrera. Se deben tener en cuenta los costes imputables tanto a gasto de personal como de material, por lo que desglosaremos el presupuesto en tales apartados.

A.1. Costes de material

En los costes de material se incluyen tanto gastos debidos al *software* (SW) utilizado, como al *hardware* (HW). También son incluidos los gastos derivados del material de oficina y gastos varios no atribuibles.

Tabla A.1: *Costes de material*

HW: Ordenador de gama media	700 €
SW: Matlab	1.100 €
Material de Oficina	150 €
Gastos varios	200 €
Coste Total	2.150 €

En la Tabla A.1, podemos observar como los costes de material ascienden a 3.150 €. En dicho presupuesto están incluidos los siguientes gastos: la compra de un ordenador de gama media, la compra de las licencias necesarias para el SW utilizado (Matlab), la compra de material de oficina (bolígrafos, papel, fotocopias, impresiones, encuadernaciones, etc.) y diversos gastos no atribuibles

(llamadas telefónicas, desplazamientos, etc.).

A.2. Costes de Personal y Dirección

Para realizar los cálculos necesarios para estimar los costes de personal, debemos conocer las distintas fases que ha tenido el proyecto, así como las horas empleadas en cada una de ellas.

Tabla A.2: *Fases del Proyecto*

Fase 1	Definición objetivos del proyecto	75 horas
Fase 2	Documentación	100 horas
Fase 3	Desarrollo del software	250 horas
Fase 4	Pruebas realizadas	170 horas
Fase 5	Redacción de la memoria del proyecto	180 horas
	Tiempo Total	775 horas

Una vez deducido el tiempo total destinado al desarrollo del proyecto (775 horas), para obtener el coste derivado, es necesario tener en cuenta los honorarios correspondientes a un ingeniero de telecomunicación. Según el *Baremo de honorarios orientativos para trabajos profesionales en 2004* publicado por el Colegio Oficial de Ingenieros de Telecomunicaciones, [21], el coste de una laboral de un ingeniero de telecomunicaciones asciende (para el 2004) a 70 €/hora. Esto supone un coste de personal de 24.412 € para las 775 horas trabajadas (aplicando un factor de corrección de 0.45). Adicionalmente, es necesario añadir el coste derivado de la dirección del proyecto, llevada a cabo por el Dr. Francisco-Javier González Serrano, que empleó aproximadamente unas 230 horas, lo que supone un coste de 7.245 €.

El coste total debido al personal y la dirección se muestra en la Tabla A.3.

Tabla A.3: *Costes de Personal y Dirección*

Coste de Personal	24.412 €
Coste de Dirección	7.245 €
Coste Total	31.657 €

A.3. Presupuesto Total

A partir los datos anteriormente expuestos, el presupuesto total necesario para el Proyecto Fin de Carrera es de 39.216,12 €, como muestra la Tabla A.4

Tabla A.4: *Presupuesto Total*

Concepto	Importe
Costes Personal y Dirección	31.657 €
Costes material	2.150 €
Base imponible	33.807 €
I.V.A. (16 %)	5.409,12 €
TOTAL	39.216,12 €

ACRÓNIMOS

PDF Probability Density Function

FP Filtro de Partículas

EKF Extended Kalman Filter

UKF Unscented Kalman Filter

KF Kalman Filter

UT Unscented Transformation

RF Radio Frecuencia

A/D Analógico / Digital

R_{ca} Radio de cobertura acústica

R_{rf} Radio de alcance RF

T_s Periodo de Seguimiento

T_l Periodo de Localización

SNR Signal to Noise Ratio

SW Software

HW Hardware

Bibliografía

- [1] Dan Li and Yu-Hen Hu. Energy-based collaborative source localization using acoustic microsensor array. In *EURASIP Journal on Applied Signal Processing*, volume 4, pages 321–337. Hindawi Publishing Corporation, 2003.
- [2] A. Córdoba J.J. Astrain, J. Villadangos. Localización y seguimiento de terminales móviles en entornos indoor. In *Actas del II Congreso Iberoamericano sobre Computación Ubicua CICU'06*, pages 255–262, 2006.
- [3] Andrés Navarro y Juan R. Velasco Iván Marsá Maestre, Miriam Machuca. Un enfoque práctico para la localización de usuarios mediante bluetooth en entornos domóticos. In *Proceedings of the 1st Iberoamerican Congress on Ubiquitous Computing CICU 2005*.
- [4] Chee-Yee Chong and Srikanta P. Kumar. Sensor networks: Evolution, opportunities and challenges. In *Proceedings of the IEEE*, volume 91, pages 1247–1256, 2003.
- [5] Gregory J. Pottie. Wireless sensor networks. In *Information Theory Workshop*, pages 139–140, 1998.
- [6] Sara Pino Povedano. Seguimiento y encaminamiento dirigidos por información en redes de sensores. In *PFC, Universidad Carlos III de Madrid*, 2007.
- [7] G. Pottie D. Estrin, L. Girod and M. Srivastava. Instrumenting the world with wireless sensor network. In *Acoustic, Speech and Signal Processing IEEE Proceedings*, volume 4, pages 2033–2036, 2001.
- [8] Jeffrey Hightower and Gaetano Borriello. Location sensing techniques. In *UW CSE Technical Report*, 2001.

- [9] Neil Gordon M. Sanjeev Arulampalam, Simon Maskell and Tim Clapp. A tutorial on particle filters for online nonlinear/non-gaussian bayesian tracking. In *IEEE Transactions on Signal Processing*, volume 50, pages 174–188, 2002.
- [10] Xiaohong Sheng and Yu-Hen Hu. Energy based acoustic source localization. In F. Zhao and L. Guibas, editors, *Information Processing in Sensor Networks - IPSN*, volume 2634 of *Lecture Notes in Computer Science*, pages 285–300. Springer-Verlag Berlin Heidelberg, 2003.
- [11] James Reich Juan Liu and Feng Zhao. Collaborative in-network processing for target tracking. In *EURASIP Journal on Applied Signal Processing*, volume 4, pages 378–391, 2003.
- [12] Arnaud Doucet and Adam M. Johansen. A tutorial on particle filtering and smoothing: Fifteen years later. In *Handbook of Nonlinear Filtering*, December 2008.
- [13] Juan José Pantrigo Fernández. Resolución de problemas de optimización dinámica mediante la hibridación entre filtros de partículas y metaheurísticas poblacionales. In *Tesis Doctoral*, Universidad Rey Juan, 2005.
- [14] Greg Welch and Gary Bishop. An introduction to the kalman filter. In *University of North Carolina, Department of Computer Science*.
- [15] María Isabel Ribeiro. Kalman and extended kalman filters: Concept, derivation and properties. In *Instituto de Sistemas e Robótica, Instituto Superior Técnico*.
- [16] Eric A. Wan and Rudolph van der Merwe. The unscented kalman filter for nonlinear estimation. In *Adaptive Systems for Signal Processing, Communications and Control Symposium*, pages 153–158, 2000.
- [17] Eric A. Wan y Rudolph van der Menve. The unscented kalman filter for nonlinear estimation. In *Adaptive Systems for Signal Processing, Communications, and Control Symposium 2000. ASSPCC. The IEEE 2000*, pages 153–158, 2000.
- [18] Yu Yao Guo-Jiang Zhang and Ke-Mao Ma. Line of sight rate estimation of strapdown imaging guidance system base on unscented kalman filter. In *Proceedings of the Fourth International Conference on Machine Learning and Cybernetics*, pages 18–21, 2005.
- [19] Simon J. Julier y Jeffrey K. Uhlman. Unscented filtering and nonlinear estimation. In *Proceedings of the IEEE*, volume 92, pages 401–422, 2004.

- [20] Xiao-Rong Li Yaakov Bar-Shalom and Thiagalingam Kirubarajan. *Estimation with applications to tracking and navigation*, chapter Estimation for kinematic models. John Wiley and Sons, 2001.
- [21] Página web del colegio oficial de ingenieros de telecomunicación. www.coit.es.